



TESIS - SS142501

**PEMODELAN BEBAN PUNCAK KONSUMSI LISTRIK DI
WILAYAH KUPANG MENGGUNAKAN *BAYESIAN
MIXTURE NORMAL AUTOREGRESSIVE***

MARCHY PALLO
NRP 1314 201 024

DOSEN PEMBIMBING
Prof. Drs. Nur Iriawan, M.IKomp., Ph.D.
Dr. Kartika Fithriasari, M.Si.

PROGRAM MAGISTER
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2016



TESIS - SS142501

MODELLING LOAD PEAK ELECTRICITY CONSUMPTION IN KUPANG USING *BAYESIAN MIXTURE NORMAL AUTOREGRESSIVE*

MARCHY PALLO
NRP 1314 201 024

SUPERVISORS

Prof. Drs. Nur Iriawan, M.IKomp., Ph.D.
Dr. Kartika Fithriasari, M.Si.

MAGISTER PROGRAM

DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2016


**PEMODELAN BEBAN PUNCAK KONSUMSI LISTRIK DI WILAYAH
KUPANG MENGGUNAKAN *BAYESIAN MIXTURE NORMAL
AUTOREGRESSIVE***

**Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Sains (M.Si)
di
Institut Teknologi Sepuluh Nopember
Oleh :**


**MARCHY PALLO
NRP. 1314201024**

**Tanggal Ujian : 18-Juli 2016
Periode Wisuda : September 2016**

Disetujui oleh :


**1. Prof. Drs. Nur Iriawan, M.IKomp., Ph.D.
NIP. 19621015 198803 1 002**

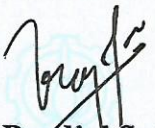
(Pembimbing I)


**2. Dr. Kartika Fithriasari, M.Si
NIP. 19691212 199303 2 002**

(Pembimbing II)


**3. Dr. Suhartono
NIP. 19710929 199512 1 001**

(Penguji)


**4. Dr. Brodjol Sutijo Suprih Ulama, M.Si.
NIP. 19820326 200312 1 004**

(Penguji)

Direktur Pascasarjana ITS


**Prof. Dr. Djauhar Manfaat, M.Sc. Ph.D
NIP. 19601202 198701 1 001**



PEMODELAN BEBAN PUNCAK KONSUMSI LISTRIK DI WILAYAH KUPANG MENGGUNAKAN *BAYESIAN MIXTURE NORMAL AUTOREGRESSIVE*

Nama mahasiswa : Marchy Pallo
NRP : 1314 201 024
Dosen Pembimbing 1 : Prof. Drs. Nur Iriawan, M.IKomp., Ph.D.
Dosen Pembimbing 2 : Dr. Kartika Fithriasari, M.Si.

ABSTRAK

Di Indonesia, persentase pertumbuhan pemakaian listrik naik setiap tahun. Adanya peningkatan tersebut menyebabkan Perusahaan Listrik Negara (PLN) harus menyediakan daya yang cukup untuk memenuhi permintaan pelanggan. Ketidacukupan daya berdampak pada berbagai sektor rumah tangga, industri dan komersial. Kupang adalah salah satu wilayah di Indonesia yang sering mengalami kekurangan daya sehingga perlu direncanakan persediaan listrik. Perencanaan persediaan listrik membutuhkan manajemen yang efisien terhadap sistem daya yang ada dan optimasi keputusan yang berkaitan dengan tambahan kapasitas berdasarkan tingginya beban puncak. Beban puncak pemakaian listrik memberikan efek drop tegangan yang bervariasi bagi pengguna listrik. Data beban puncak berindikasi memiliki bentuk *mixture* dan bersifat leptokurtik, uni-modal dan *fat-tails* sehingga cocok untuk dimodelkan menggunakan metode *Mixture Normal Autoregressive* (MNAR) dengan pendekatan Bayesian yang diimplementasikan dalam *doodle* WinBUGS. Untuk mendapatkan model terbaik dari 2 dan 3 komponen *mixture* dilihat dari nilai *Deviance Information Criterion* (DIC) terkecil. Hasil yang diperoleh yaitu model untuk 2 komponen *mixture* atau MNAR(2; [1,2,4,6],6]) memiliki nilai DIC yang minimum sebesar 16467,6 dibanding ketiga model MNAR lainnya sehingga model ini baik untuk dilakukan peramalan jangka pendek.

Kata kunci: Bayesian, Beban puncak, DIC, Listrik, *Mixture Normal Autoregressive*, WinBUGS.

MODELLING LOAD PEAK ELECTRICITY CONSUMPTION IN KUPANG USING BAYESIAN MIXTURE NORMAL AUTOREGRESSIVE

Student Name : Marchy Pallo
NRP : 1314 201 024
Supervisor 1 : Prof. Drs. Nur Iriawan, M.IKomp., Ph.D.
Supervisor 2 : Dr. Kartika Fithriasari, M.Si.

ABSTRACT

In Indonesia, the percentage of growth in electricity consumption rises every year. To fulfill the increment of consumptions in the State Electricity Company should provide enough power to satisfy customer demand. Insufficiency of power has an impact on various sectors of household, industrial, and commercial. Kupang is one of the areas in Indonesia, which is often lack the power that needs to be planned electricity supplies. Electric supply planning requires efficient management of the existing power systems and optimization decisions related to the additional capacity due to high peak loads. Electricity peak load effects varying voltage drop for power users. Data indicate as a mixture of leptokurtic, uni-modal, and fat-tails making it suitable to be modeled using Mixture Normal Autoregressive (MNAR) with a Bayesian approach implemented in WinBUGS. The best models of two and three component mixture can be seen from the smallest value of the Deviance Information Criterion (DIC). The results shows that the models with two component mixture or MNAR (2; [1,2,4,6], 6) has a minimum value of DIC (16467.6) compared to the three other models, so the best selected model is better to do short-term forecasting.

Keywords: Bayesian, DIC, Electricity, Mixture Normal Autoregressive, Load Peak, WinBUGS.

MOTTO DAN PERSEMBAHAN

MAN JADDA WA JADDA

“Barangsiapa yang bersungguh-sungguh maka pasti akan berhasil”

Tesis ini kupersembahkan untuk:

TUHAN YESUS

Bapa dan Mama

Kakak dan Adik

Yang Tercinta

KATA PENGANTAR

Puji syukur penulis panjatkan kepada Tuhan Yang Maha Esa atas rahmat dan kasih karuniaNya, penulis dapat menyelesaikan penulisan Tesis dengan judul ***“PEMODELAN BEBAN PUNCAK KONSUMSI LISTRIK DI WILAYAH KUPANG MENGGUNAKAN BAYESIAN MIXTURE NORMAL AUTOREGRESSIVE”*** ini dengan baik. Tesis ini disusun untuk memenuhi salah satu syarat memperoleh gelar Magister Sains (M.Si) di Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember Surabaya.

Terselesainya Tesis ini tidak lepas dari dukungan berbagai pihak yang telah memberikan bantuan kepada penulis. Oleh karena itu, pada kesempatan ini penulis ingin menyampaikan terima kasih kepada:

1. Kedua orang tercinta, Bapak Jarid Pallo, S.Sos dan Ibu Martha Ludji, SH atas doa dan kasih sayang tak terhingga selama ini. Kakak Yunny, adik Devy, adik Jano, dan Fry Sun atas segenap cinta dan dukungannya,
2. Bapak Prof. Drs. Nur Iriawan, M.IKomp., Ph.D dan Ibu Dr. Kartika Fithriasari, M.Si selaku dosen pembimbing dalam penyusunan Tesis ini, yang telah banyak memberikan ilmu, saran, dan penuh kesabaran serta bersedia meluangkan waktu untuk membimbing penulis selama ini,
3. Bapak Dr. Suhartono selaku Ketua Jurusan Statistika dan Bapak Dr. Brodjol Sutijo Suprih Ulama, M.Si selaku dosen penguji, yang telah banyak memberikan masukan guna kesempurnaan Tesis ini,
4. Bapak Dr.rer.pol. Heri Kuswanto, S.Si, M.Si selaku Ketua Program Pascasarjana Jurusan Statistika, yang telah memberikan waktu untuk mendukung secara moril agar terselesainya Tesis ini dengan baik,
5. Ibu Dr. Irhamah, M.Si selaku dosen penasehat akademik, yang telah mendukung dalam penyelesaian Tesis ini,
6. Bapak dan Ibu dosen Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan, Institut Teknologi Sepuluh Nopember, yang telah memberikan ilmu yang bermanfaat, serta seluruh staf administrasi akademik, laboratorium,

dan ruang baca Statistika yang telah memberikan pelayanan dan fasilitas selama perkuliahan,

7. Lembaga Pengelola Dana Pendidikan (LPDP) selaku pemberi beasiswa selama penulis menempuh studi di ITS. Terima kasih untuk memilih penulis dan teman-teman Afirmasi Kupang sebagai angkatan pertama yang menerima beasiswa unggulan ini,
8. Rekan-rekan seperjuangan Afirmasi LPDP yaitu Kak Bobby, Kak Erlin, Kak Andy, Kak Lelly, Kak Marvin, Icha, Mada, Ernes, Farly, Yopi, Zofar, dan Adik Rini yang telah menjadi saudara dalam senang maupun susah, saling mendukung dalam doa, dan saling memberi semangat selama perkuliahan dan penyusunan Tesis ini,
9. Rekan seperjuangan Magister Statistika angkatan 2014, terima kasih atas kerjasama, saran, dan kebersamaannya,
10. Keluarga besar Pallo dan Ludji yang telah memberikan perhatian, kasih sayang, dan doa selama penulis menempuh studi,
11. Semua pihak yang tidak dapat disebutkan satu persatu, yang telah membantu dan menyumbangkan pikiran guna terselesaikan Tesis ini.

Penulis menyadari bahwa dalam tulisan Tesis ini masih banyak kekurangan, sehingga kritik dan saran yang membangun dari berbagai pihak sangat diharapkan. Semoga tulisan ini memberikan manfaat bagi semua dan bermanfaat untuk pengembangan ilmu pengetahuan khususnya di bidang Statistika. Tuhan Yesus menyertai kita.

Surabaya, Juni 2016

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
MOTTO DAN PERSEMBAHAN.....	ix
KATA PENGANTAR.....	xi
DAFTAR ISI.....	xiii
DAFTAR TABEL	xv
DAFTAR GAMBAR.....	xvii
DAFTAR ALGORITMA.....	xix
DAFTAR LAMPIRAN	xxi
BAB I PENDAHULUAN	
1.1 Latar Belakang.....	1
1.2 Perumusan Masalah.....	4
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	4
1.5 Batasan Masalah	5
BAB II TINJAUAN PUSTAKA	
2.1 Identifikasi Model <i>Mixture</i> dengan Histogram.....	7
2.2 <i>Time Series Analysis</i>	7
2.2.1 Autokorelasi dan Autokorelasi Parsial.....	8
2.2.2 Model <i>Time Series</i> Stasioner.....	9
2.2.3 Model <i>Autoregressive Integrated Moving Average</i>	10
2.3 Model <i>Mixture</i>	10
2.4 Pendekatan Bayesian pada Distribusi <i>Mixture</i>	11
2.4.1 Metode Estimasi pada Distribusi <i>Mixture</i>	12
2.4.2 Distribusi <i>Prior</i>	13
2.4.3 <i>Likelihood</i> pada Model <i>Mixture</i>	13
2.5 <i>Markov Chain Monte Carlo</i>	14

2.5.1 <i>Gibbs Sampler</i>	15
2.5.2 <i>Credible Interval</i>	18
2.6 <i>Mixture Normal Distribution</i>	19
2.7 <i>Mixture Normal Autoregressive</i>	20
2.8 WinBUGS	22
2.9 Kelistrikan	23
BAB III METODOLOGI PENELITIAN	
3.1 Sumber Data dan Variabel Penelitian	27
3.2 Metode dan Tahapan Analisis.....	27
BAB IV ANALISIS DAN PEMBAHASAN	
4.1 Karakteristik Beban Puncak Konsumsi Listrik di Kupang	31
4.1.1 Karakteristik Data dalam Harian	32
4.1.2 Karakteristik Data dalam Mingguan.....	32
4.1.3 Karakteristik Data dalam Bulanan.....	34
4.1.4 Karakteristik Data dalam Tahunan	35
4.1.5 Identifikasi Kestasioneran Data.....	35
4.2 Model <i>Autoregressive</i> Beban Puncak Konsumsi Listrik di Kupang	36
4.2.1 Tahap Identifikasi	36
4.2.2 Tahap Estimasi Parameter	37
4.2.3 Tahap Pengecekan Diagnosa	38
4.3 Model <i>Bayesian Mixture Normal Autoregressive</i>	40
4.3.1 Pemodelan MNAR (2; p_1 , p_2).....	40
4.3.2 Pemodelan MNAR (3; p_1 , p_2 , p_3).....	46
4.3.2 Seleksi Model Terbaik.....	49
BAB V KESIMPULAN DAN SARAN	
5.1 Kesimpulan	51
5.2 Saran.....	53
DAFTAR PUSTAKA	55
LAMPIRAN	57
BIOGRAFI	95

:DAFTAR TABEL

Tabel 4.1	Nilai Estimasi Parameter Model I.....	37
Tabel 4.2	Nilai Estimasi Parameter Model II.....	37
Tabel 4.3	Nilai Estimasi Parameter Model III.....	37
Tabel 4.4	Nilai statistik uji <i>Chi-square error</i> model I, II, dan III.....	39
Tabel 4.5	Nilai statistik uji Kolmogorov-Smirnov.....	39
Tabel 4.6	Estimasi Parameter 2 Komponen <i>Mixture</i> MNAR (2;1,[1,2,4,6]).....	41
Tabel 4.7	Estimasi Parameter 2 Komponen <i>Mixture</i> MNAR (2;1,6).....	43
Tabel 4.8	Estimasi Parameter MNAR (2; [1,2,4,6],6).....	45
Tabel 4.9	Estimasi Parameter MNAR (3; 1,[1,2,4,6],6).....	48
Tabel 4.10	Nilai DIC Model MNAR.....	50

DAFTAR GAMBAR

Gambar 1.1	<i>Time series plot</i> dari Beban Puncak dan Daya Mampu Pembangkit Kupang tahun 2015.....	2
Gambar 2.1	Histogram data beban puncak konsumsi listrik wilayah Kupang.....	24
Gambar 2.2	<i>Marginal plot</i> data beban puncak konsumsi listrik wilayah Kupang setelah di <i>differencing</i>	25
Gambar 3.1	<i>Flow chart</i> penelitian.....	29
Gambar 4.1	<i>Time series plot</i> data asli.....	31
Gambar 4.2	<i>Time series plot</i> data setelah di imputasi.....	31
Gambar 4.3	<i>Chart</i> dari Beban Puncak dalam harian tahun 2011-2015.....	32
Gambar 4.4	<i>Chart</i> dari Beban Puncak dalam mingguan.....	33
Gambar 4.5	<i>Chart</i> dari Beban Puncak pada hari raya Natal dan Tutup Tahun 2015.....	34
Gambar 4.6	<i>Chart</i> dari Beban Puncak dalam bulanan.....	34
Gambar 4.7	<i>Chart</i> dari Beban Puncak dalam tahunan.....	35
Gambar 4.8	<i>ACF Plot</i> Beban Puncak Konsumsi Listrik di Kupang.....	35
Gambar 4.9	<i>Time Series Plot</i> setelah di <i>differencing</i>	35
Gambar 4.10	<i>PACF Plot</i> setelah data <i>differencing</i>	36
Gambar 4.11	Struktur doodle WinBUGS dari MNAR (2; 1,[1,2,4,6]).....	40
Gambar 4.12	Struktur doodle WinBUGS dari MNAR (2; 1,6).....	43
Gambar 4.13	Struktur doodle WinBUGS dari MNAR (2;[1,2,4,6],6).....	45
Gambar 4.14	Struktur doodle WinBUGS 3 komponen <i>mixture</i> atau model MNAR (3; 1,[1,2,4,6],6).....	47

DAFTAR ALGORITMA

Algoritma 2.1	Algoritma <i>Gibbs Sampler</i>	17
---------------	--------------------------------	----

DAFTAR LAMPIRAN

Lampiran 1	Input Program SAS untuk AR(1).....	59
Lampiran 2	Input Program SAS untuk AR([1,2,4,6]).....	60
Lampiran 3	Input Program SAS untuk Model AR(6).....	61
Lampiran 4	Output SAS untuk Model AR(1).....	62
Lampiran 5	Output SAS untuk Model AR([1,2,4,6]).....	63
Lampiran 6	Output SAS untuk Model AR(6).....	64
Lampiran 7	Perbandingan Model Autoregressive yang Signifikan.....	65
Lampiran 8	Input WinBUGS untuk 2 Komponen Mixture Model AR(1) & AR([1,2,4,6]).....	66
Lampiran 9	Output WinBUGS untuk 2 Komponen Mixture Model AR(1) & AR([1,2,4,6]).....	67
Lampiran 10	Plot Time Series, Density, dan Autocorrelation untuk 2 Komponen Mixture Model AR(1) & AR([1,2,4,6]).....	68
Lampiran 11	Input WinBUGS untuk 2 Komponen Mixture Model AR(1) & AR(6).....	72
Lampiran 12	Output WinBUGS untuk 2 Komponen Mixture Model AR(1) & AR(6).....	73
Lampiran 13	Plot Time Series, Density, dan Autocorrelation untuk 2 Komponen Mixture Model AR(1) & AR(6).....	74
Lampiran 14	Input WinBUGS untuk 2 Komponen Mixture Model AR([1,2,4,6]) & AR(6).....	79
Lampiran 15	Output WinBUGS untuk 2 Komponen Mixture Model AR([1,2,4,6]) & AR(6).....	80
Lampiran 16	Plot Time Series, Density, dan Autocorrelation untuk 2 Komponen Mixture Model AR([1,2,4,6]) & AR(6).....	81
Lampiran 17	WinBUGS untuk 3 Komponen Mixture Model AR(1), AR([1,2,4,6]) & AR(6).....	87
Lampiran 18	Output WinBUGS untuk 3 Komponen Mixture Model AR(1), AR([1,2,4,6]) & AR(6).....	88

Lampiran 19	Plot Time Series, Density, dan Autocorrelation untuk 3 Komponen Mixture Model AR(1), AR([1,2,4,6]) & AR(6).....	89
-------------	---	----

BAB 1


PENDAHULUAN

1.1. Latar Belakang

Listrik merupakan energi yang sangat penting dan telah menjadi salah satu kebutuhan pokok yang tidak bisa dipisahkan dari kehidupan manusia. Adanya fasilitas ini membuat semua aktivitas manusia menjadi lebih mudah. Ketiadaan listrik akan menghambat kemajuan teknologi serta aktivitas manusia yang lainnya. Di Indonesia, energi listrik dikelola oleh Perusahaan Listrik Negara (PLN) yang merupakan salah satu Badan Usaha Milik Negara (BUMN). Persentase pertumbuhan pemakaian listrik semester-1/ 2013 naik sebesar 7,2 % dibanding semester yang sama tahun lalu. Total pemakaian listrik semester-1/2013 adalah sebesar 90,48 Tera Watt hour (TWh) dan pada semester-1/2012 sebesar 84,43 TWh. Peningkatan dalam penggunaan energi listrik dipengaruhi oleh berbagai faktor antara lain pertambahan jumlah penduduk, pertumbuhan perekonomian yang signifikan, perkembangan industri, serta kemajuan teknologi berbasis energi listrik yang berkembang pesat.

Pelanggan golongan industri yang menggunakan listrik untuk keperluan produktif tumbuh sebesar 8,3%. Jumlah pelanggan Industri pada Semester-1/2013 bertambah 4,5% dibanding posisi pada Semester-1/2012. Di sisi lain, golongan rumah tangga pada Semester-1/2013 jumlah pelanggannya tumbuh 8% dibanding Semester-1/2012, sedangkan konsumsi kilo Watt hour (kWh) hanya tumbuh 5,5%. Pertumbuhan yang terbalik ini merupakan hal yang baik karena perbaikan rasio elektrifikasi semakin cepat. Untuk pelanggan rumah tangga kecil daya 900 Volt Ampere (VA) jumlah pelanggan pada semester 1 2013 tumbuh tinggi sebesar 11,7 % dibanding semester yang sama tahun lalu. Demikian juga, pelanggan rumah tangga kelas menengah dengan daya 3500 VA – 5500 VA jumlah pelanggan pada semester-1/2013 tumbuh 11,3% dibanding semester-1/2012. Adanya peningkatan tersebut menyebabkan PLN harus menyediakan daya yang cukup untuk memenuhi permintaan pelanggan. Ketidalcukupan daya berdampak pada berbagai sektor rumah tangga, industri dan komersial.

Kupang adalah salah satu wilayah di Indonesia yang sering mengalami kekurangan daya. Hal ini terlihat dari Gambar 1.1 berikut ini. Sering kali, Daya Mampu Pembangkit (DMP) yang dihasilkan tidak mencukupi permintaan pelanggan yang tinggi yang dapat dilihat pada Beban Puncak (BP). Dikarenakan banyak mesin pembangkit yang sering rusak sehingga tidak dapat menghasilkan daya untuk memenuhi kebutuhan pelanggan. Oleh karena itu, perlu dilakukan perencanaan yang efisien untuk memenuhi permintaan pelanggan dan pihak PLN bisa lebih meminimalisir rusaknya mesin pembangkit di wilayah Kupang.



Gambar 1.1 *Time Series Plot* dari Beban Puncak dan Daya Mampu Pembangkit Kupang Tahun 2015

Perencanaan persediaan listrik membutuhkan manajemen yang efisien terhadap sistem daya yang ada dan optimasi keputusan yang berkaitan dengan tambahan kapasitas (Harsono, 2005). Untuk itu diperlukan suatu prediksi mengenai permintaan daya oleh pelanggan. Salah satu metode yang dapat digunakan untuk memprediksi permintaan daya adalah metode deret waktu.

Data deret waktu merupakan serangkaian data pengamatan yang berasal dari sumber tetap yang terjadinya berdasarkan indeks waktu t secara berurutan dan interval waktu yang tetap. Analisis deret waktu stokastik adalah deret waktu dengan nilai observasi yang akan datang bersifat probabilistik, berdasarkan observasi yang lampau. Analisis data deret waktu pada dasarnya digunakan untuk melakukan analisis data yang mempertimbangkan pengaruh waktu. Data-data

yang dikumpulkan secara periodik berdasarkan urutan waktu, bisa dalam jam, hari, minggu, bulan, kuartal dan tahun, bisa dilakukan analisis menggunakan metode analisis data deret waktu. Analisis data deret waktu tidak hanya dilakukan untuk satu variabel (*univariate*) tetapi juga bisa untuk banyak variabel (*multivariate*).

Pola permintaan harian, mingguan, atau bahkan bulanan serta permintaan beban puncak (*peak demand*) memberikan munculnya sifat leptokurtik, multimodal dan *fat-tails* pada data beban listrik ini. Beberapa fenomena yang muncul dalam kondisi riil menunjukkan bahwa adanya variabilitas yang tinggi pada data. Pemodelan dengan *univariate* biasa dan dipolakan dengan univariabel pada kondisi tersebut akan mengakibatkan adanya bias dalam analisisnya. Oleh karena itu, digunakan model *mixture* sebagai gabungan dari beberapa subpopulasi yang masing-masing berpola univariabel. Setiap subpopulasi merupakan komponen penyusun dari model *mixture* serta mempunyai proporsi yang bervariasi untuk masing-masing komponennya. Bercampurnya beberapa pola data menjadi satu akan membentuk sebuah pola baru sebagai model *mixture* yang dapat mengakomodasi variabilitas data yang tidak dapat terwakili apabila dipolakan univariabel (Bohning dan Seidel, 2003).

Untuk mengatasi sifat leptokurtik, uni-modal dan *fat-tails* pada data dapat dipresentasikan ke dalam bentuk *Mixture Normal Autoregressive* (MNAR). Munculnya metode MNAR diawali oleh karya Wong dan Li (2000) dengan estimasi parameter menggunakan algoritma *Expectation and Maximization* (EM). Metode ini cocok untuk memandang rentetan data serial, termasuk pergerakan data konsumsi listrik sebagai bentuk *mixture* (McLachlan dan Basford, 1988).

Beberapa penelitian terdahulu mengenai model *mixture* seperti Wong dan Li (2001) menggunakan dua komponen model *mixture* dengan bobot logistik yang bergantung pada waktu dan variabel eksogen. Estimasi parameter ditunjukkan dengan algoritma *Expectation and Maximization* (EM) dan seleksi *lag autoregressive* difasilitasi oleh *Bayesian Information Criterion* (BIC). Carvalho dan Tanner (2005, 2006, 2007) menggunakan pendekatan *mixture-of-experts* untuk model nonlinear dalam model *time series*. Penulis-penulis tersebut menggunakan estimasi *maximum likelihood*, investigasi *identifiability* dan

estimasi Normal asimtotik serta menggunakan *Akaike's Information Criterion* (AIC) dan BIC untuk menyeleksi banyaknya komponen-komponen dalam model. Hal yang sama juga dilakukan oleh Prado *et al.* (2006) yang menggunakan hirarki *mixtures-of-experts* dengan model *vector autoregressive*, dengan parameter yang sudah diestimasi oleh algoritma EM dan seleksi model yang ditunjukkan oleh BIC. Lau dan So (2008) menggunakan proses *mixture Dirichlet* dari proses *autoregressive* untuk model yang fleksibel *density* prediktifnya dari *time series*.

Dalam penelitian ini, akan dicari model dengan metode MNAR untuk menganalisis kemungkinan adanya *mixture* pada data beban puncak konsumsi listrik di wilayah Kupang dengan pendekatan Bayesian. Sebelum dimodelkan, akan dilihat distribusi atau sebaran sehingga pemodelan akan lebih tepat. Diasumsikan bahwa parameter yang tidak diketahui dalam model *autoregressive* mengikuti sebuah distribusi *mixture*.

1.2. Perumusan Masalah

1. Bagaimana karakteristik beban puncak konsumsi listrik di wilayah Kupang?
2. Bagaimana model *autoregressive* beban puncak konsumsi listrik di Kupang?
3. Bagaimana model *Bayesian mixture normal autoregressive* pada data beban puncak konsumsi listrik harian wilayah Kupang?

1.3. Tujuan Penelitian

1. Mengetahui karakteristik beban puncak konsumsi listrik di Kupang.
2. Memperoleh model *autoregressive* beban puncak konsumsi listrik di Kupang.
3. Memperoleh model *Bayesian mixture normal autoregressive* beban puncak konsumsi listrik harian wilayah Kupang.

1.4. Manfaat Penelitian

1. Menambah wawasan keilmuan statistika dalam penerapan metode *time series*, pendekatan menggunakan *Bayesian mixture* untuk model *time series* serta model *mixture normal autoregressive model*.
2. Mengetahui model *mixture autoregressive* khususnya pada data beban konsumsi listrik di wilayah Kupang.
3. Mendapat perencanaan daya atau beban untuk PT. PLN wilayah Kupang sebagai bahan pertimbangan pengambilan keputusan.

1.5. Batasan Masalah

Batasan masalah dalam penelitian ini yaitu :

1. Data yang digunakan adalah beban puncak konsumsi listrik di wilayah Kupang pada malam hari saja.
2. Banyaknya komponen *mixture* yang digunakan ditentukan 2 dan 3 komponen.

...halaman ini sengaja dikosongkan...

BAB II

TINJAUAN PUSTAKA

2.1. Identifikasi Model *Mixture* dengan Histogram

Histogram merupakan metode tertua dan paling sering digunakan dalam estimasi suatu distribusi data. Namun, metode ini masih sangat sederhana karena estimasi distribusinya hanya didasarkan pada perkiraan gambar histogram yang terbentuk. Pembentukan histogram suatu data pengamatan adalah dengan menentukan titik awal x_0 dan lebar h pada setiap kelas intervalnya, sehingga histogram yang terbentuk berada pada interval $(x_0 + mh, x_0 + (m+1)h)$ dengan m adalah bilangan bulat, sehingga keberadaan kelas-kelas interval sangat dipengaruhi oleh nilai x_0 dan lebar kelas interval h (Silverman, 1986).

Misalkan dari data pengamatan $x = (x_1, x_2, \dots, x_n)$, Silverman pada tahun 1986 mendefinisikan distribusi dari histogram sebagai berikut ini :

$$\hat{f}(x) = \frac{1}{nh} p \quad (2.1)$$

dengan : n = banyaknya data

p = banyaknya data yang ada pada kelas yang sama dengan x

Dari persamaan (2.1), tampak bahwa untuk membangun suatu distribusi menggunakan histogram ditentukan oleh banyaknya data, sedangkan banyaknya data dalam interval sangat dipengaruhi oleh keberadaan titik awal x_0 dan lebar kelas h yang digunakan. Adanya ketergantungan dari titik awal x_0 dan lebar kelas h dalam penentuan distribusi suatu data merupakan kelemahan dari metode histogram. Namun metode ini dapat digunakan untuk deteksi awal bentuk distribusi suatu data secara deskriptif.

2.2. *Time Series Analysis*

Time series merupakan serangkaian data pengamatan yang terjadi berdasarkan indeks waktu secara berurutan dengan interval waktu tetap (Wei, 2006). Sedangkan analisis *time series* adalah salah satu prosedur statistika yang

diterapkan untuk meramalkan struktur probabilistik keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan.

2.2.1. Autokorelasi dan Autokorelasi Parsial

a. Fungsi Autokorelasi

Autokorelasi menunjukkan korelasi antara pengamatan ke- t (Z_t) dan pengamatan ke- $t-k$ (Z_{t-k}). Suatu proses Z_t dikatakan stasioner apabila nilai *mean* $E(Z_t) = \mu$ dan *varians* $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ adalah konstan. Fungsi autokorelasi antara Z_t dan Z_{t-k} yaitu (Wei, 2006):

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{Cov(Z_t, Z_{t-k})}{\sqrt{Var(Z_t)Var(Z_{t-k})}} \quad (2.2)$$

dengan catatan bahwa $Var(Z_t) = Var(Z_{t-k}) = \gamma_0$.

γ_k dinamakan fungsi autokovarian pada lag ke- k , γ_0 adalah varians dari Z_t dan t adalah banyaknya observasi. Suatu proses stasioner dapat diketahui dari fungsi autokovarian γ_k dan fungsi autokorelasi ρ_k yaitu (Wei, 2006) :

1. $\gamma_0 = Var(Z_t); \rho_0 = 1$.
2. $|\gamma_k| \leq \gamma_0; |\rho_k| \leq 1$
3. $\gamma_k = \gamma_{-k}$ dan $\rho_k = \rho_{-k}$ untuk semua k

b. Fungsi Autokorelasi Parsial

Autokorelasi parsial digunakan untuk mengukur tingkat keeratan antara Z_t dan Z_{t-k} apabila pengaruh dari lag waktu (*time lag*) $1, 2, 3, \dots, k-1$ dianggap terpisah. Fungsi autokorelasi parsial adalah suatu fungsi yang menunjukkan besarnya korelasi parsial antara pengamatan pada waktu ke t dengan pengamatan waktu-waktu sebelumnya.

Rumus autokorelasi parsial atau ϕ_{kk} adalah:

$$\phi_{kk} = corr(Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \quad (2.3)$$

Nilai ϕ_{kk} secara empiris telah dijabarkan oleh Durbin (1960) dalam Wei (2006: 22) yaitu sebagai berikut:

$$\hat{\phi}_{kk} = \frac{\hat{\rho}_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \hat{\rho}_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \hat{\rho}_j} \quad (2.4)$$

dimana $\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j}$, untuk $j = 1, 2, 3, \dots, k-1$.

2.2.2. Model Time Series Stasioner

a. Model Autoregressive (AR)

Model *autoregressive* dengan orde p atau $AR(p)$ menjelaskan bahwa observasi ke- t dipengaruhi oleh p observasi sebelumnya. Bentuk umum model $AR(p)$ adalah

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + \varepsilon_t \quad (2.5)$$

atau

$$\begin{aligned} (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \dot{Z}_t &= \varepsilon_t \\ \phi_p(B) \dot{Z}_t &= \varepsilon_t \end{aligned} \quad (2.6)$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \text{ adalah komponen } AR(p)$$

$$\dot{Z}_t = Z_t - \mu$$

B adalah operator *backward shift* yang didefinisikan sebagai $B^k Z_t = Z_{t-k}$

ε_t adalah *error* yang bersifat *white noise* pada waktu ke- t dengan *mean* 0 dan variansi konstan σ_ε^2 .

$\phi_1, \phi_2, \phi_3, \dots, \phi_p$ adalah koefisien *autoregressive* orde p .

b. Model Moving Average (MA)

Model *moving average* dengan orde q atau $MA(q)$ menjelaskan bahwa observasi ke- t dipengaruhi oleh q error sebelumnya. Bentuk umum model $MA(q)$ adalah

$$\dot{Z}_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.7)$$

Atau

$$\dot{Z}_t = \theta_q(B) \varepsilon_t \quad (2.8)$$

dengan

$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ adalah komponen MA(q).

$\theta_1, \theta_2, \theta_3, \dots, \theta_q$ adalah koefisien *moving average* orde q .

2.2.3. Model Autoregressive Integrated Moving Average (ARIMA)

Suatu proses Z_t dikatakan mengikuti model ARIMA yang non stasioner dalam rata-rata jika ada orde d ($d \geq 1$). Orde d digunakan untuk memodelkan kejadian yang tidak stasioner dalam rata-rata dimana d menyatakan orde *differencing*. Secara umum operasi *differencing* yang menghasilkan suatu kejadian (proses) baru yang stasioner, misal W_t adalah

$$W_t = (1 - B)^d \dot{Z}_t \quad (2.9)$$

Model umum untuk ARIMA (p, d, q) adalah

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d \dot{Z}_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (2.10)$$

dengan :

p adalah orde *autoregressive*.

d adalah orde *differencing*.

q adalah orde *moving average*.

2.3. Model Mixture

Setiap subpopulasi merupakan suatu komponen dari populasinya yang tersusun secara *mixture* dengan proporsi yang bervariasi untuk setiap komponennya. Setiap model *mixture* dapat terlihat dari pola datanya yang cenderung terlihat sebagai bentuk gabungan dari beberapa grup atau komponen (Gelman *et al.*, 2004). Setiap komponen itu memiliki distribusi yang sama maupun berbeda dengan komponen lainnya. Distribusi *mixture* menggabungkan komponen-komponen tersebut untuk mendapatkan hasil analisis yang lebih akurat dari suatu data yang kompleks. Distribusi *mixture* menyediakan kerangka parametrik yang fleksibel dalam pemodelan dan analisis statistik (Marin *et al.*, 2001).

Model *mixture* telah dikembangkan dengan berbagai pendekatan, yaitu *Expectation and Maximisation* (EM), *Neural Network*, *Maximum Likelihood*, dan *Bayesian* (McLachlan & Peel, 2000). Pemodelan *mixture* akan lebih akurat hasilnya karena lebih mendekati distribusi data yang sebenarnya. Hal ini dilakukan dengan membuat komponen *mixture* yang merupakan pendekatan dari distribusi data yang kompleks. Namun demikian, komponen *mixture* yang lebih banyak tidak selalu menjadi kurva distribusinya lebih baik (Iriawan, 2000)

Suatu model *mixture* merupakan sebuah model peluang yang digambarkan dengan densitas sebagai berikut (Bernardo & Giron, 1988) :

$$f(t|P, x, \theta) = \sum_{k=1}^K P_k f_k(t|x, \theta_k), \quad P_k > 0, \quad \sum_{k=1}^K P_k = 1 \quad (2.11)$$

dimana $P = (P_1, P_2, \dots, P_k)$, $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ dan K adalah banyaknya komponen dalam *mixture*. Dalam model ini, $f_k(t|x, \theta_k)$ adalah peluang dari x dalam populasi P_k , yang mana merupakan fungsi densitas model atau *mixture* dengan parameter θ_k . Untuk sebuah populasi, $f_k(t|P, x, \theta)$ merupakan model sebuah populasi dengan setiap model masing-masing komponennya adalah merupakan suatu representasi distribusi atau model dari subpopulasinya sehingga sebuah populasi akan memungkinkan mempunyai beberapa model penyusun $f(t|x, \theta_k)$ yang sama atau saling berbeda satu sama lain seperti *Poisson*, *Normal*, atau distribusi lainnya dan bahkan sebuah *mixture*. Selanjutnya, P_k adalah proporsi dari komponen *mixture* dengan $0 \leq P_k \leq 1, \sum_{k=1}^K P_k = 1$. Model pada Persamaan (2.11) disebut sebagai model *finite mixture* yang berlaku untuk model dengan jumlah komponen k tertentu.

2.4. Pendekatan Bayesian pada Distribusi *Mixture*

Dalam pendekatan Bayesian, data digunakan sebagai informasi untuk mengestimasi suatu parameter dan digolongkan ke dalam dua kelompok, yaitu data pengamatan saat ini yang bersifat sesaat selama studi dan data yang bersifat *long memory histogram* yang dikumpulkan di masa lampau (Iriawan, 2001). Hal

ini merupakan kelebihan dari metode *Bayes* yang terletak pada kemampuannya dalam mengakomodasi informasi awal yang dimiliki oleh peneliti, dimana kesimpulan akhir dari dugaan parameter distribusi didasarkan tidak hanya pada informasi sampel saja melainkan juga didasarkan atas informasi subjektif dari peneliti. Informasi awal ini yang disebut sebagai *prior* biasanya dikualifikasi dalam bentuk distribusi dari parameternya (Box & Tiao, 1973 dalam Nijahatur Rejki, 2015).

Dalam Bayesian, semua parameter di dalam model dianggap sebagai variabel sehingga untuk mengestimasi parameter model, *posterior* gabungan parameter model harus dibangun terlebih dahulu dengan mengacu pada informasi data yang diketahui. Spesifikasi dari distribusi *prior* sangat penting dalam metode Bayesian karena *prior* tersebut mempengaruhi bentuk *posterior* yang digunakan sebagai alat pengambil keputusan. Bila informasi *prior* tersedia maka informasi distribusi *prior* akan terangkum di dalamnya.

2.4.1. Metode Estimasi pada Distribusi *Mixture*

Metode histogram merupakan cara mendeteksi adanya kecenderungan bahwa suatu data berdistribusi *mixture* (Iriawan, 2001). Estimasi distribusi *mixture* menggunakan metode Bayesian dilakukan dengan menemukan distribusi *posterior*. Kemudian estimasi nilai setiap parameter modelnya dapat ditentukan setelah semua *prior* yang relevan telah diberikan (Gamerman, 1997).

Estimasi model *mixture* dengan banyak parameter ini akan memunculkan kesulitan tersendiri. Dimensi model yang besar maupun kompleksnya struktur model yang tinggi akan memberikan kesulitan pada masing-masing langkah estimasi parameternya. Untuk mengatasi hal tersebut, maka dapat digunakan pendekatan Bayesian yang memiliki kelebihan dalam penarikan kesimpulan secara numerik, yaitu dengan menggunakan metode *Markov Chain Monte Carlo* (MCMC) (Iriawan, 2001).

2.4.2. Distribusi *Prior*

Untuk mengetahui estimator Bayes suatu parameter perlu diketahui bentuk *prior*-nya. Distribusi *prior* dapat diperoleh melalui data masa lalu yang telah ada

yang disebut *prior "data based"*. Namun, jika data masa lalu tidak tersedia, distribusi *prior* dipilih berdasarkan kepercayaan peneliti, dan *prior* jenis ini disebut dengan *prior "non data based"*.

Berdasarkan teorema Bayes, informasi awal yang digunakan sebagai distribusi *prior* dan informasi sampel yang dinyatakan dengan fungsi *likelihood* dikombinasikan untuk membentuk distribusi *posterior*. Jika kurang tepat dalam menentukan distribusi *prior* maka distribusi *posterior*-nya juga akan kurang tepat. Ada beberapa tipe distribusi *prior* yang dikenal dalam metode Bayesian (Box & Tiao, 1973), yaitu:

1. *Conjugate prior* dan *Non-conjugate prior* adalah *prior* yang terkait pola model *likelihood* dari data.
2. *Proper prior* dan *Improper prior (Jeffrey prior)* adalah *prior* yang terkait dengan pemberian bobot atau densitas di setiap titik terdistribusi secara *uniform* atau tidak.
3. *Informative prior* dan *Non-informative prior* adalah *prior* yang terkait dengan diketahui atau belum diketahuinya pola atau frekuensi data.
4. *Pseudo prior* menjelaskan *prior* yang terkait dengan pemberian nilai yang disetarakan dengan hasil elaborasi pendapat kaum *frequentist*.

2.4.3. Likelihood pada Model Mixture

Fungsi *likelihood* distribusi *mixture* berbeda dengan fungsi *likelihood* distribusi *univariate*. Jika terdapat data pengamatan sebanyak n yang terdekomposisi ke dalam K kelompok data (subpopulasi) yang masing-masing mempunyai distribusi maka fungsi *likelihood* model *mixture* tersusun dari beberapa *likelihood* data di setiap subpopulasi menurut distribusi masing-masing. Berdasarkan model *mixture* pada persamaan (2.11), fungsi *likelihood* model *mixture* adalah:

$$l_{mix} = \prod_{i=1}^n f_{mix}(x_i | \theta)$$

$$l_{mix} = \prod_{i=1}^{n_1} P_1 f(x_{i1} | \theta_1) + \prod_{i=1}^{n_2} P_2 f(x_{i2} | \theta_2) + \dots + \prod_{i=1}^{n_K} P_K f(x_{iK} | \theta_K) \quad (2.12)$$

dengan syarat persamaan (2.11) adalah $n_1 + n_2 + n_3 + \dots + n_K$ merupakan penyusun *autoregressive* dan K adalah banyaknya komponen *mixture*.

2.5. *Markov Chain Monte Carlo* (MCMC)

MCMC pertama kali dikembangkan oleh Geman dan Geman (1984) untuk memfasilitasi metode alternatif ini. Metode Bayesian dan MCMC sangat sulit untuk dipisahkan. Untuk model *posterior* dari suatu Bayesian yang sangat rumit, diperlukan proses integrasi yang sulit dalam menentukan *marginal posterior* suatu parameter, maka diperlukan sebuah solusi alternatif dengan pendekatan numerik. Adapun cara dari metode MCMC (utamanya *Gibbs Sampler*) dalam memfasilitasi penyelesaian numerik ini adalah dengan membangkitkan data sampel parameter θ (katakan $\theta = (\pi, \sigma^2, \beta)$), yang diberlakukan sebagai suatu *random* vektor dengan distribusi tertentu dan mempunyai nilai dugaan $f(\bar{\Theta})$ dari fungsi yang terkait dalam $f(\Theta)$ (Iriawan, 2003). Karena semua parameter $\theta = (\pi, \sigma^2, \beta)$ dalam Bayesian diperlukan sebagai variabel, maka inferens pada estimasinya akan didasarkan pada :

$$\begin{aligned} f(\bar{\Theta}) &= E(f(\Theta) | x^n) \\ &= \int f(\theta) d\mu(\theta) \\ &= \int f(\theta) p(\theta | x^n) d(\theta) \end{aligned} \quad (2.13)$$

dimana x^n adalah data yang telah diketahui dengan n yang menandakan vektor data. Pada banyak kasus, persamaan (2.13) tidak mudah untuk dihitung. Kesulitan pertama yang akan dihadapi adalah pada distribusi bersyarat $f(\Theta)$ yang tidak akan mudah diselesaikan secara analitis. Sehingga dalam mengestimasi fungsi densitas $f(\bar{\Theta})$ pada persamaan (2.13) digunakanlah metode MCMC (Iriawan, 2003).

MCMC yang merupakan perpaduan sifat rantai *Markov* pada integrasi dengan simulasi *Monte Carlo*. Integrasi *Monte Carlo* merupakan teknik integrasi dengan metode komputasi untuk memperoleh sebuah nilai harapan (*Expetation*).

MCMC menyelesaikan persamaan (2.13) dengan cara membangkitkan nilai-nilai parameter θ dari tiap model *marginal*-nya dengan menggunakan metode *rejection sampling*. MCMC memberikan dua cara mudah untuk mengestimasi $f(\Theta)$. Pertama, MCMC dapat menyederhanakan model yang kompleks dan berdimensi tinggi, $\theta = (\pi, \sigma^2, \beta)$ menjadi *uni*-variabel dan *uni*-dimensi sehingga akan mudah untuk menyelesaikan persamaan (2.13). Kedua, MCMC untuk menghitung persamaan (2.13) dengan cara mengestimasinya melalui bangkitan N deretan data (Iriawan, 2003).

2.5.1. Gibbs Sampler

Metode *Gibbs Sampler* dikembangkan pertama kali dalam penelitian di bidang komputer grafik pada tahun 1984 di Amerika Serikat oleh S. Geman dan D. Geman. *Gibbs Sampler* merupakan generator yang sangat efisien, sehingga sering digunakan sebagai generator variabel-variabel *random* pada analisis data yang menggunakan metode MCMC. Metode *Gibbs Sampler* dapat didefinisikan sebagai suatu teknik simulasi untuk membangkitkan variabel *random* dari suatu distribusi tertentu secara tidak langsung, tanpa harus menghitung fungsi densitas dari suatu distribusi data (Casella & George, 1992).

Dalam banyak kasus, terlihat bahwa cara kerja *Gibbs Sampler* hanya didasarkan pada sifat dasar rantai *Markov*. Secara detail metode ini dapat diterangkan sebagai berikut (Geman dan Geman, 1984; Iriawan, 2003) :

Anggap beberapa variabel *random*, $\beta_0, \beta_1, \beta_2, \dots, \beta_p, \sigma_d$, tergabung dalam suatu distribusi gabungan,

$$f(\beta_0, \beta_1, \beta_2, \dots, \beta_p, \sigma_d) \quad (2.14)$$

dimana distribusi bersyarat :

$$\begin{aligned} &f(\beta_0 | \beta_1, \beta_2, \dots, \beta_p, \sigma_d) \\ &f(\beta_1 | \beta_0, \beta_2, \dots, \beta_p, \sigma_d) \\ &\vdots \\ &f(\sigma_d | \beta_0, \beta_1, \beta_2, \dots, \beta_p) \end{aligned} \quad (2.15)$$

dianggap telah diketahui. Untuk mengetahui karakteristik distribusi dari x atau sering dikatakan sebagai distribusi *marginal* $f(x)$, maka harus dilakukan proses integral rangkap sebanyak variabel *random* yang tersisa dalam distribusi gabungannya, yaitu :

$$f(x) = \int \dots \int f(\beta_0, \beta_1, \beta_2, \dots, \beta_p, \sigma_d) d\beta_0 d\beta_1 d\beta_2 \dots d\beta_p d\sigma_d \quad (2.16)$$

Pengintegralan dalam persamaan (2.16) jelas akan sangat sulit atau bahkan tidak mungkin dilakukan jika fungsi gabungannya sangat kompleks. Untuk menyelesaikan permasalahan ini, dapat menggunakan metode *Gibbs Sampler* dengan syarat distribusi bersyarat setiap variabel yang terkandung di dalamnya telah diketahui. Dengan metode ini, bentuk fungsi *marginal*-nya dapat diketahui tanpa harus menghitung dan mengetahui bagaimana karakteristik setiap *marginal* variabel *random* yang berada di dalam fungsi gabungan. Pendekatan analisis karakteristik distribusi *marginal* dengan *Gibbs Sampler* ini dilakukan melalui pembangkitan data secara numerik dengan simulasi *Monte Carlo* pada distribusi bersyarat variabel *random* yang sedang dipelajari terhadap semua sisa variabel *random* yang ada di dalam fungsi distribusi gabungannya (Iriawan, 2003).

Pada persamaan (2.14) ingin diketahui karakteristik distribusi *marginal* $f(\beta_0)$, maka *Gibbs Sampler* dengan metode *Monte Carlo* akan membangkitkan beberapa data X yang berdistribusi $f(\beta_0, \beta_1, \beta_2, \dots, \beta_p, \sigma_d)$ dan karakteristik distribusi *marginal*-nya. Persamaan (2.16) diestimasi berdasarkan pada data-data hasil simulasi *Monte Carlo* tersebut. Hal ini menjelaskan bahwa dengan data yang sangat besar jumlahnya, maka nilai-nilai yang diperoleh berdasarkan data tersebut akan mencerminkan kondisi suatu populasinya.

Pembangkitan data setiap variabel *random* dalam fungsi kepadatan gabungan dengan menggunakan *Gibbs Sampler* adalah sebagai berikut (Iriawan, 2003):

Bangkitkan $\beta_{01}, \beta_{02}, \dots, \beta_{0n}$, dari $f(\beta_0 | \beta_1, \beta_2, \dots, \beta_p, \sigma_d)$

Bangkitkan $\beta_{11}, \beta_{12}, \dots, \beta_{1n}$, dari $f(\beta_1 | \beta_0, \beta_2, \dots, \beta_p, \sigma_d)$

Bangkitkan $\beta_{21}, \beta_{22}, \dots, \beta_{2n}$, dari $f(\beta_2 | \beta_0, \beta_1, \dots, \beta_p, \sigma_d)$

⋮

Bangkitkan $\sigma_{d1}, \sigma_{d2}, \dots, \sigma_{dn}$, dari $f(\sigma_d | \beta_0, \beta_1, \beta_2, \dots, \beta_p)$

Adapun tahapan proses pembangkitan data setiap variabel *random* dalam fungsi kepadatan gabungan dapat dituliskan ke dalam bentuk algoritma sebagai berikut:

Algoritma 2.1 Algoritma *Gibbs Sampler*

1. Menentukan nilai awal $\theta = \beta_0^0, \beta_1^0, \beta_2^0, \dots, \beta_p^0, \sigma_d^0$
2. Membangkitkan,
 - Tahap 1. β_0^1 dari $f(\beta_0 | \beta_1^0, \beta_2^0, \beta_3^0, \dots, \beta_p^0, \sigma_d^0)$
 - Tahap 2. β_1^1 dari $f(\beta_1 | \beta_0^1, \beta_2^0, \beta_3^0, \dots, \beta_p^0, \sigma_d^0)$
 - Tahap 3. β_2^1 dari $f(\beta_2 | \beta_0^1, \beta_1^1, \beta_3^0, \dots, \beta_p^0, \sigma_d^0)$
 - ⋮
 - Tahap d . σ_d^1 , dari $f(\sigma_d | \beta_0^1, \beta_1^1, \beta_2^1, \dots, \beta_p^1)$

Sehingga diperoleh nilai data bangkitan pada iterasi pertama yaitu $\theta^{(1)} = \beta_0^1, \beta_1^1, \beta_2^1, \dots, \beta_p^1, \sigma_d^1$.
3. Menggunakan hasil bangkitan pada iterasi pertama sebagai nilai awal pada iterasi kedua. Kemudian membangkitkan tahap berikut ini:
 - Tahap 1. β_0^2 dari $f(\beta_0 | \beta_1^1, \beta_2^1, \beta_3^1, \dots, \beta_p^1, \sigma_d^1)$
 - Tahap 2. β_1^2 dari $f(\beta_1 | \beta_0^2, \beta_2^1, \beta_3^1, \dots, \beta_p^1, \sigma_d^1)$
 - Tahap 3. β_2^2 dari $f(\beta_2 | \beta_0^2, \beta_1^2, \beta_3^1, \dots, \beta_p^1, \sigma_d^1)$
 - ⋮
 - Tahap d . σ_d^2 , dari $f(\sigma_d | \beta_0^2, \beta_1^2, \beta_2^2, \dots, \beta_p^2)$

Sehingga diperoleh nilai data bangkitan pada iterasi kedua yaitu $\theta^{(2)} = \beta_0^2, \beta_1^2, \beta_2^2, \dots, \beta_p^2, \sigma_d^2$.

Proses ini dilakukan hingga iterasi ke- N

Menggunakan hasil bangkitan pada iterasi ke $N-1$ sebagai nilai awal pada iterasi ke- N . kemudian membangkitkan tahap berikut ini:

Tahap 1. β_0^N dari $f(\beta_0 | \beta_1^{N-1}, \beta_2^{N-1}, \beta_3^{N-1}, \dots, \beta_p^{N-1}, \sigma_d^{N-1})$

Tahap 2. β_1^N dari $f(\beta_1 | \beta_0^N, \beta_2^{N-1}, \beta_3^{N-1}, \dots, \beta_p^{N-1}, \sigma_d^{N-1})$

Tahap 3. β_2^N dari $f(\beta_2 | \beta_0^N, \beta_1^N, \beta_3^{N-1}, \dots, \beta_p^{N-1}, \sigma_d^{N-1})$

\vdots

Tahap d . σ_d^N , dari $f(\sigma_d | \beta_0^N, \beta_1^N, \beta_2^N, \dots, \beta_p^N)$

Sehingga diperoleh nilai data bangkitan pada iterasi ke- N yaitu

$$\theta^{(N)} = \beta_0^N, \beta_1^N, \beta_2^N, \dots, \beta_p^N, \sigma_d^N.$$

4. Berdasarkan N buah data yang sudah dibangkitkan, kemudian diestimasi karakteristik setiap fungsi kepadatan *marginal* $f(\beta_1), f(\beta_2), \dots, f(\beta_p), f(\sigma_d)$.

Metode *Gibbs Sampler* sering dinamakan sebagai metode MCMC karena sifat dan karakteristik pembangkitan data *randomnya* sangat erat sekali dengan sifat *Markov chain*. Sifatnya yaitu *Gibbs Sampler* membangkitkan data *random* pada setiap iterasi atau bangkitan data ke- I sangat tergantung pada nilai *random* pada iterasi kedua, ketiga, dan seterusnya sampai ke- N yang sebelumnya (Iriawan, 2003).

2.5.2. *Credible Interval*

Perbedaan mendasar dalam inferensia statistik dengan pendekatan klasik dan pendekatan Bayesian adalah dalam pembentukan selang kepercayaan. Dalam pendekatan klasik selang kepercayaan dikenal dengan *confidence interval* yang dibentuk berdasarkan sebaran estimasi parameter. Sedangkan dalam pendekatan Bayesian, selang kepercayaan dibentuk dengan pendekatan *highest posterior density* (HPD) yang dikenal dengan *Bayesian confidence interval* atau *credible interval* (Box & Tiao, 1973; Koop, 2003).

Dengan menggunakan konsep densitas seimbang, pembentukan *credible interval* dilakukan dengan menggunakan lokasi modus sebagai acuan pusat data.

Dengan demikian *credible interval* dapat digunakan untuk pembuatan selang kepercayaan dari pola data yang tidak simetris (Box & Tiao, 1973; Gelman *et al.*, 2004).

Definisi yang diuraikan oleh Koop (2003) dimisalkan X adalah variabel *random* dengan PDF $f(x|\theta)$ dan θ adalah parameter yang akan diestimasi, maka $100(1-\alpha)\%$ *credible interval* untuk θ adalah sebagai berikut:

$$P(\theta \in [a, b] | x) = \int_a^b f(\theta | x) d\theta = 1 - \alpha, \quad 0 \leq \alpha \leq 1 \quad (2.17)$$

Persamaan (2.17) menunjukkan bahwa θ adalah variabel *random* dengan selang yang *fixed*. *Credible interval* tersebut tidak unik sehingga akan ada beberapa kemungkinan selang interval $[a, b]$ yang memuat $100(1-\alpha)\%$ distribusi *posterior* (King, et, al., 2010). *Credible interval* yang unik akan diperoleh apabila batas bawah (a) adalah *quantile* $\frac{\alpha}{2}$ dan batas atas (b) adalah *quantile* $\frac{\alpha}{2}$ (King *et al.*, 2010), atau:

$$\int_{-\infty}^a f(\theta | x) d\theta = \frac{\alpha}{2} = \int_b^{\infty} f(\theta | x) d\theta \quad (2.18)$$

2.6. Mixture Normal Distribution

Distribusi *mixture* Normal dengan lokasi (*mean*) yang berbeda dapat membantu dalam identifikasi pola data miring. Apabila parameter lokasi tersebut cukup jauh antara satu dengan yang lainnya, maka distribusi campurannya akan memberikan pola data yang sangat berbeda, yaitu multi-modal. Pola data yang diperoleh dari pengamatan tidak selalu dapat memenuhi keinginan peneliti. Ada kalanya pola data sangat tidak beraturan, bahkan multi-modal (Iriawan, 2012)

Distribusi campuran yang pola datanya multi-modal sering digunakan dalam identifikasi data dengan tujuan untuk pengelompokkan (*clustering*), baik untuk banyaknya kelompok komponen (komponen distribusi dalam distribusi campuran) yang diketahui (*known number of component*) maupun yang tidak diketahui (*unknown number of component*). Dalam pengelompokkan, metode

dalam distribusi campuran dengan komponen tertentu dinamakan metode non-hirarki atau *K-means*. Metode hirarki dalam teori pengelompokkan, dalam distribusi campuran digunakan untuk distribusi campuran dengan banyaknya komponen yang tidak diketahui. Metode untuk mendeteksi banyaknya komponen yang tepat untuk suatu data, telah dikembangkan *reversible jump Markov chain Monte Carlo* (RJMCMC) oleh Green pada tahun 1995. Dengan menggunakan RJMCMC, identifikasi pola data sudah akan mampu memasuki pola yang adaptif, baik itu membentuk pola yang uni-modal maupun multi-modal.

2.7. *Mixture Normal Autoregressive* (MNAR)

Wong dan Li (2000) memperkenalkan model distribusi campuran Normal autoregressive (MNAR) untuk memodelkan suatu data *time series* non-linear. Model tersebut memuat K komponen distribusi dengan masing-masing adalah *Gaussian Autoregressive*. Model ini dipakai oleh Wong dan Li untuk data *time series* finansial yang berbentuk ekor yang panjang dan tebal (*heavy-tails*), bahkan multi-modal sehingga perpaduan dalam distribusi campuran Normal yang terdiri atas beberapa Normal *Autoregressive* (AR), model simultan dari semua pola tersebut dapat direpresentasikan. Seperti model yang telah dikemukakan oleh MacLachlan dan Peel (2000) yang menunjukkan bahwa sifat *heavy-tails* dan efek *outliers* yang tidak setimbang di dua ekor densitasnya akan mewarnai tipe model campurannya, sehingga model MNAR yang dikembangkan oleh Wong dan Li (2000) jika diterapkan pada data seperti itu tidak dapat memberikan hasil pemodelan yang tepat.

Mixture Normal Autoregressive (MNAR) dengan K komponen penyusun yang biasa dinotasikan sebagai MNAR $(K; p_1, p_2, \dots, p_k)$ dapat dituliskan sebagai berikut (Iriawan, 2012) :

$$F(Z_t | F_{t-1}) = \sum_{k=1}^K P_k \Phi \left(\frac{Z_t - \phi_{k,0} - \sum_{i=1}^{p_k} \phi_{k,i} Z_{t-i}}{\sigma_k} \right). \quad (2.19)$$

Atau dapat dikatakan Z_t merupakan komponen MNAR dalam persamaan (2.19) sebagai berikut:

$$Z_t = \begin{cases} \phi_{1,0} + \sum_{i=1}^{p_1} \phi_{1,i} Z_{t-i} + \sigma_1 \varepsilon_1(t), & \text{dengan probabilitas } P_1 \\ \phi_{2,0} + \sum_{i=1}^{p_2} \phi_{2,i} Z_{t-i} + \sigma_2 \varepsilon_2(t), & \text{dengan probabilitas } P_2 \\ \vdots \\ \phi_{K,0} + \sum_{i=1}^{p_K} \phi_{K,i} Z_{t-i} + \sigma_K \varepsilon_K(t), & \text{dengan probabilitas } P_K \end{cases} \quad (2.20)$$

dengan :

$F(\dot{Z}_t | F_{t-1})$ adalah fungsi distribusi bersyarat dari pengamatan \dot{Z}_t dengan diketahui pengamatan-pengamatan sebelum pengamatan \dot{Z}_t ;

F_{t-1} adalah informasi data pengamatan hingga saat $t-1$;

$\Phi(\cdot)$ adalah fungsi distribusi kumulatif Normal standar;

$$\sum_{k=1}^K P_k = 1, P_k > 0, \quad k = 1, 2, 3, \dots, K ;$$

$\phi_{k,i}, i = 0, 1, \dots, p_k$ adalah koefisien *autoregressive* pada komponen ke- k ;

$\sigma_k > 0$ adalah skala untuk komponen *noise* ke- k .

Model MNAR ini mempunyai *conditional mean* sebagai berikut (Iriawan, 2012) :

$$\begin{aligned} E(Z_t | F_{t-1}) &= \sum_{k=1}^K P_k (\phi_{k,0} + \phi_{k,1} Z_{t-1} + \dots + \phi_{k,p_k} Z_{t-p_k}) \\ &= \sum_{k=1}^K P_k \mu_{k,t} \end{aligned} \quad (2.21)$$

Conditional variance model MNAR $(K; p_1, p_2, \dots, p_k)$ adalah sebagai berikut (Iriawan, 2012):

$$Var(\dot{Z}_t | F_{t-1}) = \sum_{k=1}^K P_k \sigma_k^2 + \sum_{k=1}^K P_k \mu_{k,t} - \left(\sum_{k=1}^K P_k \mu_{k,t} \right)^2 \quad (2.22)$$

dengan $\mu_{k,t}$ seperti pada persamaan (2.21). Komponen $\sum_{k=1}^K P_k \mu_{k,t} - \left(\sum_{k=1}^K P_k \mu_{k,t} \right)^2$ dalam persamaan (2.22) akan bernilai non-negatif dan akan bernilai nol hanya jika $\mu_{1,t} = \mu_{2,t} = \mu_{3,t} = \dots = \mu_{K,t}$. Model MNAR $(K; p_1, p_2, \dots, p_k)$ pada persamaan

(2.19) akan mempunyai kondisi stasioner orde pertama dan orde kedua masing-masing sebagai berikut:

$$\begin{aligned} |P_1\phi_{1,1} + P_2\phi_{2,1} + \dots + P_K\phi_{K,1}| &< 1 \\ |P_1\phi_{1,1}^2 + P_2\phi_{2,1}^2 + \dots + P_K\phi_{K,1}^2| &< 1 \end{aligned} \quad (2.24)$$

Sisi lain pemanfaatan hasil MNAR adalah diketahuinya probabilitas perpindahan antar model AR yang satu ke yang lain selama periode proses serial berlangsung. Kondisi stasioner MNAR sangat bergantung pada proporsi komponen *mixture* P_k .

2.8. WinBUGS

WinBUGS adalah suatu *software* yang dibangun khusus untuk pemodelan yang berdasarkan simulasi stokastik dengan metode *Bayesian* dengan cara membangkitkan variabel *random* dari *posterior* distribusi parameter model (Lunn dkk., 2000; Ntzoufras, 2009). BUGS adalah singkatan dari *Bayesian inference Using Gibbs Sampling*. Pemodelan menggunakan WinBUGS dapat dilakukan secara *textual* dengan menggunakan bahasa pemrograman yang sudah dideklarasikan yaitu bahasa BUGS maupun *graphical* dengan menggunakan DoodleBUGS *interface*.

Pengguna yang belum familiar dengan bahasa pemrograman dapat dengan mudah menggambarkan struktur modelnya ke dalam perangkat doodle yang merupakan *interface* dari WinBUGS. Penjelasan mengenai enam subsistem penting untuk program WinBUGS 1.4 adalah sebagai berikut (Lunn dkk., 2000):

1. *Doodle* merupakan tampilan grafis yang digunakan *user* untuk membangun suatu model regresi dengan menggunakan DAG (*Directed Acyclic Graph*).
2. *Bugs* adalah subsistem yang memiliki beberapa peranan, yaitu mendefinisikan *grammar* untuk spesifikasi model yang telah dibuat, mengumpulkan dan menyimpan representasi model, membentuk pemetaan antara variabel dalam model statistika dengan objek yang mempresentasikan model tersebut, dan mengendalikan algoritma simulasi MCMC.

3. *Samples* adalah subsistem yang menghubungkan detail model yang tersimpan dan monitors yang membentuk output berupa teks dan grafis seperti kesimpulan statistic serta gambar densitas *posterior*.
4. *Updater* adalah subsistem yang membentuk objek yang melakukan proses iterasi MCMC berdasarkan data sampel yang diberikan.
5. *Monitors* adalah subsistem yang mendefinisikan tipe objek yang bertanggung jawab untuk menyimpan sampel yang telah terbentuk dari node.
6. *Graph* adalah subsistem yang megekspor tipe-tipe data dalam suatu node pembangun model grafis.
7. *PKlink* dan *PKBugs* adalah subsistem yang dibangun khusus untuk analisis data *pharmacokinetic*.

2.9. Kelistrikan


Pada UU No. 20 Tahun 2002 menjelaskan bahwa tenaga listrik adalah suatu bentuk energi sekunder yang dibangkitkan, ditransmisikan, dan didistribusikan untuk segala macam keperluan, tidak termasuk listrik yang digunakan untuk komunikasi, elektronika, atau isyarat. Besarnya konsumsi listrik yang digunakan tergantung dari perilaku konsumen dalam menggunakan alat listriknya. Dari perilaku konsumen tersebut, selanjutnya PT. PLN (Persero) harus mampu menyesuaikan daya listrik yang disalurkan dari waktu ke waktu. Ada tiga komponen utama didalam sistem ketenagalistrikan diantaranya system pembangkit, transmisi, dan distribusi. Sistem pembangkitan tersusun atas sejumlah unit-unit pembangkit yang secara umum menyebar pada daerah pelayanan interkoneksi jaringan sistem tenaga listrik.

Pada sistem pembangkit ini biasanya mempunyai lebih dari satu unit pembangkit yang jumlahnya sesuai dengan kebutuhan dan sarana infrastruktur untuk mendukung pengoperasian sistem-sistem tersebut. Sistem pembangkit terbagi menjadi beberapa macam diantaranya Pusat Pembangkitan Listrik Tenaga Diesel (PLTD), Pusat Pembangkitan Listrik Tenaga Uap (PLTU), Pusat Pembangkitan Listrik Tenaga Air (PLTA), Pusat Pembangkitan Listrik Tenaga Panas Bumi (PLTP), dan lain-lain. Sistem transmisi merupakan proses penyaluran


tenaga listrik dari pembangkit tenaga listrik menuju distribusi listrik sehingga dapat disalurkan ke konsumen. Fungsi dari transmisi diantaranya dapat menyalurkan energi listrik dari pembangkit ke gardu induk, meyalurkan dari satu gardu induk ke gardu induk yang lainnya, dan dari gardu induk ke jaringan tegangan menengah dan gardu distribusi. Sedangkan sistem distribusi merupakan bagian dari sistem tenaga listrik yang umumnya banyak mengalami gangguan. Karena sistem ini adalah sistem yang hubungannya paling dekat dengan pelanggan (Marsudi, 2006).

Beban puncak pemakaian listrik, diistilahkan WBP (waktu beban puncak), dipetakan oleh PLN terjadi pada 2 waktu dalam sehari yaitu siang dan malam. Pada siang hari, WBP terjadi pada pukul 09.00-14.00 dan malam hari terjadi pada pukul 17.00-22.00. Efek bagi pengguna listrik adalah tegangan yang drop atau voltase turun hingga mencapai dibawah 200V. Besarnya drop tegangan sangat bervariasi di berbagai wilayah tergantung dari besarnya beban dari Trafo Distribusi masing-masing. Oleh karena itu, perlu direncanakan atau diprediksikan besarnya beban atau daya yang harus dihasilkan oleh Trafo Distribusi wilayah masing-masing, termasuk di wilayah Kupang. Berbagai masalah timbul di masyarakat akibat adanya pemadaman listrik bergiliran dikarenakan beban atau daya yang dibutuhkan tidak mencukupi sehingga dalam penelitian ini akan dimodelkan dalam bentuk *mixture* dengan pendekatan Bayesian.

Indikasi bahwa data beban puncak ini memiliki bentuk *mixture* terlihat dari gambar 2.1. pada histogram tersebut diduga bahwa data mengikuti beberapa distribusi normal. Terlihat pula dalam *marginal plot* pada Gambar 2.2 bahwa beban puncak konsumsi listrik wilayah Kupang pada malam hari memiliki sifat leptokurtik, uni-modal dan *fat-tails*.



Gambar 2.1 *Histogram data beban puncak konsumsi listrik wilayah Kupang*



Gambar 2.2 *Marginal plot data beban puncak konsumsi listrik wilayah Kupang setelah di differencing*

Berdasarkan data yang memenuhi sifat itulah sehingga cocok bila dimodelkan ke dalam bentuk *Mixture Normal Autoregressive* (MNAR) dengan pendekatan Bayesian yaitu *Gibbs Sampler*.

...halaman ini sengaja dikosongkan..

BAB III

METODOLOGI PENELITIAN

3.1. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder dari PT. PLN (Persero) wilayah Kupang, Nusa Tenggara Timur. Data yang diperoleh yakni Beban Puncak (BP) dalam harian pada malam hari dari tanggal 1 Januari 2011 sampai 31 Desember 2015 di sistem pembangkit Kupang yang berjumlah 1862 pengamatan. Data ini juga bisa diakses melalui <http://komit.pln.co.id/> untuk data kelistrikan di Indonesia Timur. Variabel penelitian yang digunakan adalah jumlah Beban Puncak (BP) konsumsi listrik harian dalam satuan Mega Watt (MW) yang terjadi pada pukul 17.00-22.00 WITA.


3.2. Metode dan Tahapan Penelitian

Metode dan tahapan penelitian yang akan dilakukan untuk menjawab rumusan masalah pada penelitian ini adalah:

1. Mengeksplorasi data melalui statistika deskriptif.
2. Mengaplikasikan model *Autoregressive* (AR) dengan menggunakan data beban puncak konsumsi listrik dengan langkah-langkah sebagai berikut :
 - a. Identifikasi data dengan melakukan plot time series dan ACF. Diperiksa apakah data time series sudah stasioner atau belum, baik dalam rata-rata maupun dalam varians.
 - b. Bila data time series belum stasioner dalam rata-rata maka dilakukan *differencing* dan/atau belum stasioner dalam varians maka dilakukan transformasi Box-Cox.
 - c. Membuat plot ACF dan PACF. Untuk mendapatkan orde model AR yang mungkin maka dilihat dari plot PACF dengan menggunakan bantuan *software* MINITAB dan SAS.
3. Mendapatkan model *mixture normal autoregressive* dengan langkah-langkah berikut :
 - a. Identifikasi awal data berdistribusi *mixture* dengan membuat histogram pada data yang telah di *differencing*.

- b. Menentukan banyaknya komponen *mixture*. Apabila hasil identifikasi data dengan menggunakan metode histogram dapat diduga banyaknya komponen penyusun *mixture* yang terbentuk, maka selanjutnya adalah menentukan banyak komponen *mixture* yang mungkin. Namun dibatasi banyaknya komponen yaitu 2 dan 3 komponen.
- c. Pembentukan model *mixture* dengan banyaknya komponen *mixture* diketahui dengan Bayesian yang diimplementasikan pada WinBUGS.
- d. Pemeriksaan model dan pemilihan model terbaik menggunakan kriteria pemilihan model terbaik dengan *DIC*.
- e. Interpretasi model *mixture normal autoregressive*.

Untuk lebih jelas, metode dan tahapan penelitian dapat dilihat dalam diagram alir berikut ini.



Gambar 3.1 Flow chart penelitian

...halaman ini sengaja dikosongkan..


BAB IV

ANALISIS DAN PEMBAHASAN


Pada bab ini akan dilakukan analisis dan pembahasan hasil penelitian untuk menjawab perumusan masalah yang meliputi karakteristik beban puncak konsumsi listrik di wilayah Kupang pada malam hari, mencari model *autoregressive* serta mendapatkan model *Bayesian Mixture Normal Autoregressive* beban puncak konsumsi listrik pada malam hari di wilayah Kupang untuk 2 (dua) dan 3 (tiga) komponen *mixture*. Dari hasil terakhir tersebut akan dibandingkan untuk memperoleh model terbaik antara 2 dan 3 komponen *mixture* tersebut.

4.1. Karakteristik Beban Puncak Konsumsi Listrik di Kupang

Langkah awal sebelum dilakukan analisis deskriptif untuk mengetahui karakteristik dari beban puncak konsumsi listrik di Kupang pada malam hari. Gambar 4.1 menunjukkan bahwa pada hari Senin tanggal 20 Agustus 2012 terlihat bahwa data bernilai 0. Hal tersebut terjadi dikarenakan *block out* yaitu mesin mati secara keseluruhan sehingga tidak menghasilkan daya. Kemudian pada hari Jumat tanggal 28 Februari 2014 terlihat bahwa data bernilai 0. Hal ini disebabkan kesalahan teknis dari operator dalam pengisian data karena ini bukan hanya terjadi pada system pembangkit Kupang saja melainkan pada seluruh system pembangkit di NTT.



Gambar 4.1 *Time Series Plot* data asli




Gambar 4.2 *Time Series Plot* data setelah di imputasi

Dengan melihat deskripsi data di atas, untuk mendapatkan hasil analisis yang baik maka akan dilakukan preprosesing data pada data yang bernilai 0 dengan cara mengimputasi. Dipilih imputasi dengan mengganti nilai 0 menggunakan nilai *mean* dari data mingguan yang dekat dengan data bernilai 0 tersebut. Data bernilai 0 pada tanggal 20 Agustus 2012 diganti dengan nilai *mean* dari data tanggal 19 Agustus 2012 sampai 25 Agustus 2012 yaitu 32,76. Data bernilai 0 pada tanggal 28 Februari 2014 diganti dengan nilai *mean* dari tanggal 24 Februari 2014 sampai 2 Maret 2014 yaitu 43,08. Dengan demikian, data ini bisa digunakan untuk analisis. Data tersebut divisualisasikan dalam *time series plot* pada Gambar 4.2.

4.1.1 Karakteristik Data Dalam Harian


Berdasarkan Gambar 4.3 terlihat bahwa selama 5 tahun yaitu dari tahun 2011-2015, beban puncak konsumsi listrik tertinggi pada hari rabu dan kamis. Berbanding terbalik dengan hari sabtu dan minggu yang terendah. Tidak ada alasan yang pasti mengapa demikian, namun diperkirakan beban puncak tertinggi pada hari-hari itu disebabkan oleh hari-hari raya secara nasional terjadi pada hari-hari tersebut yang menyebabkan naiknya pemakaian listrik. Misalnya, pada tahun 2015, beban puncak tertinggi terjadi pada hari rabu tanggal 23 Desember, hari sebelum Malam Natal.



Gambar 4.3 *Chart* dari Beban Puncak dalam harian tahun 2011-2015

4.1.2 Karakteristik Data Dalam Mingguan


Gambar 4.4 memberikan deskripsi untuk beban puncak konsumsi listrik secara mingguan dalam satu bulan. Terlihat bahwa minggu pertama lebih tinggi dan diikuti oleh minggu keempat.



Gambar 4.4 *Chart* dari Beban Puncak dalam mingguan

Minggu pertama merupakan pemakaian dengan beban puncak tertinggi pada hari kamis, diikuti minggu ke empat, ke tiga dan ke dua yaitu pada hari jumat. Ini menunjukkan keterkaitan dengan karakteristik dalam harian bahwa hari kamis merupakan hari dengan beban puncak tertinggi. Pemilihan bulan Maret tahun 2015 untuk menunjukkan karakteristik dalam bulan dikarenakan pada bulan tersebut tidak ada hari libur nasional sehingga tidak ada pengaruh naik turunnya pemakaian listrik.


Selain melihat pola data secara mingguan, Gambar 4.5 berikut ini merupakan *chart* untuk minggu menjelang dan setelah hari raya Natal tahun 2015. Daerah Kupang merupakan mayoritas beragama Kristen dan Katolik sehingga akan dilihat pola data pada hari raya Natal untuk mengetahui apakah hal tersebut berpengaruh pada peningkatan atau penurunan daya listrik. Pada Gambar 4.5 terlihat bahwa sehari sebelum Malam Natal tanggal 24 Desember 2015 yaitu hari rabu tanggal 23 Desember lebih tinggi dibandingkan Malam Natal dan hari raya Natal. Ini disebabkan oleh karena kebanyakan masyarakat Kupang mempersiapkan kebutuhan yang diperlukan sebelum Malam Natal dan Natal. Begitu pula yang terjadi pada hari sebelum Tutup Tahun tanggal 31 Desember yaitu hari rabu tanggal 30 Desember yang lebih tinggi dalam pemakaian listrik.



Gambar 4.5 *Chart* dari Beban Puncak pada hari raya Natal dan Tutup Tahun 2015

4.1.3 Karakteristik Data dalam Bulanan


Gambar 4.6 menunjukkan beban puncak konsumsi listrik di Kupang pada malam hari dari tahun 2011-2015 yang dibuat dalam bentuk *chart* bulanan. Berdasarkan Gambar 4.6 ini terlihat bahwa bulan–bulan penutupan tahun lebih tinggi dibandingkan dengan yang lainnya. Hal ini disebabkan aktivitas malam hari sebelum hari raya Natal dan Tahun Baru banyak menggunakan lampu hias baik itu di rumah tangga maupun sepanjang jalan dan pertokoan. Bulan February merupakan bulan dengan pemakaian terendah karena bulan ini merupakan bulan dengan jumlah hari paling sedikit.



Gambar 4.6 *Chart* dari Beban Puncak dalam bulanan

4.1.4 Karakteristik Data dalam Tahun


Berikut ini akan dideskripsikan karakteristik beban puncak konsumsi listrik di Kupang pada malam hari dari tahun 2011 sampai 2015 yang dibuat *chart* dalam bentuk tahunan. Pada Gambar 4.7 terlihat terjadi peningkatan dari tahun ke tahun untuk pemakaian listrik. Ini berarti dari tahun ke tahun terjadi pembangunan yang cukup signifikan dan menyebabkan naiknya rasio elektrifikasi.




Gambar 4.7 *Chart* dari Beban Puncak dalam tahunan

4.1.5 Identifikasi Kestasioneran Data

Stasioneritas berarti fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan varians dari fluktuasi tersebut juga konstan setiap waktu. Berikut ini akan dilakukan identifikasi stasioneritas data dengan melihat *Time Series Plot* dan *ACF Plot* dari data.



Gambar 4.8 *ACF Plot* Beban Puncak Konsumsi Listrik di Kupang



Gambar 4.9 *Time Series Plot* setelah di *differencing*


Dari Gambar 4.8 menunjukkan *ACF Plot* yang turun lambat menuju 0 dan *Time Series Plot* pada Gambar yang 4.2 tampak bahwa data belum stasioner dalam *mean* atau masih ada unsur *trend* sehingga perlu dilakukan *differencing* satu kali. Hasil dari *differencing* akan dilakukan pengecekan lagi kestasioneran data. Setelah dilakukan *differencing*, seperti yang ditunjukkan dalam Gambar 4.9 secara visual data relatif stasioner dalam *mean*.

4.2. Model Autoregressive Beban Puncak Konsumsi Listrik di Kupang

Dalam pembentukan model *autoregressive* terdapat beberapa tahapan yang harus dilakukan yaitu tahap identifikasi, estimasi, dan pengecekan diagnosa. Tahap identifikasi untuk menduga model yang terbentuk dengan melihat plot dari *PACF*. Tahap estimasi untuk mengestimasi parameter dari model *autoregressive* dugaan. Tahap pengecekan diagnosa untuk mengetahui apakah model dugaan sudah memenuhi syarat kebaikan model.

4.2.1 Tahap Identifikasi

Dalam tahap ini akan dilihat model bentuk dari plot *PACF* data yang sudah stasioner. Dari Gambar 4.9 terlihat bahwa *PACF* cenderung *cuts off* setelah lag 6. Model *autoregressive* dugaan yang teridentifikasi berdasarkan plot *PACF* adalah AR(1) yang akan disebut sebagai model I, AR([1,2,4,6]) sebagai model II, dan AR(6) sebagai model III. Model-model tersebut merupakan ketiga model yang dipilih dengan nilai AIC terendah dari beberapa model yang signifikan. Hasil perhitungan model-model yang signifikan dapat dilihat pada Lampiran 7 beserta nilai AIC.



Gambar 4.9 *PACF Plot* setelah data *differencing*

4.2.2 Tahap Estimasi Parameter

Setelah mendapatkan model dugaan selanjutnya dilakukan estimasi parameter dari model tersebut. Dengan bantuan *software SAS*, parameter-parameter dari model I, II, dan III diestimasi menggunakan metode *Conditional Least Square*. Berikut ini adalah hasil estimasi parameter model I, II, dan III.

Tabel 4.1 Nilai Estimasi Parameter Model I

Parameter	Estimate	t value	p_value	Lag
ϕ_1	-0,35564	-16,25	<0,0001	1

Tabel 4.2 Nilai Estimasi Parameter Model II

Parameter	Estimate	t value	p_value	Lag
ϕ_1	-0,43028	-18,89	<0,0001	1
ϕ_2	-0,21042	-9,21	<0,0001	2
ϕ_4	-0,10012	-4,69	<0,0001	4
ϕ_6	-0,08104	-3,79	<0,0001	6

Tabel 4.3 Nilai Estimasi Parameter Model III

Parameter	Estimate	t value	p_value	Lag
ϕ_1	-0,51572	-22,33	<0,0001	1
ϕ_2	-0,36706	-14,29	<0,0001	2
ϕ_3	-0,29688	-11,31	<0,0001	3
ϕ_4	-0,28754	-10,95	<0,0001	4
ϕ_5	-0,19073	-7,41	<0,0001	5
ϕ_6	-0,17410	-7,52	<0,0001	6

Pada hasil estimasi parameter model I, II, dan III yang ditunjukkan dalam tabel di atas, terdapat pula hasil uji statistik secara parsial yang menjelaskan signifikansi parameter pada model I. Sehingga, akan dilakukan uji signifikansi parameter dengan hipotesis sebagai berikut:

H_0 : Parameter model tidak signifikan

H_1 : Parameter model signifikan

Dengan taraf signifikansi $\alpha = 0,05$ dan statistik uji yang digunakan adalah uji t .

Pada pengujian ini, tolak H_0 jika $p_value < \alpha$ atau $t_{hitung} > t_{tabel}$ yang berarti parameter model signifikan. Terlihat pada Tabel 4.1, 4.2, dan 4.3 bahwa $p_value < \alpha$ sehingga dapat disimpulkan bahwa tolak H_0 artinya parameter-parameter model I, II, dan III signifikan.

4.2.3 Tahap Pengecekan Diagnosa

Tahapan selanjutnya adalah pengecekan diagnosa dengan melakukan pengujian asumsi *error* model dugaan. Pengujian ini terdiri dari pengujian asumsi *error* yang memenuhi syarat *white noise* dan normalitas. Pengujian asumsi *error white noise* dilakukan dengan hipotesis sebagai berikut:

H_0 : *Error* yang memenuhi asumsi *white noise*

H_1 : *Error* yang tidak memenuhi asumsi *white noise*

Dengan taraf signifikansi $\alpha = 0,05$ dan statistik uji yang digunakan adalah uji *Chi-square*. Pada pengujian asumsi *error white noise*, tolak H_0 jika $p_value < \alpha$ atau $\chi^2_{hitung} > \chi^2_{tabel}$ artinya *error* yang tidak memenuhi asumsi *white noise*. Berdasarkan Tabel 4.4 terlihat bahwa $p_value < \alpha$ sehingga dapat dikatakan *error* tidak memenuhi asumsi *white noise* untuk ketiga model dugaan tersebut. Selanjutnya akan dilakukan uji normalitas untuk ketiga model dugaan.

Tabel 4.4 Nilai statistik uji *Chi-square error* model I, II, dan III

Model	Sampai Lag	df	χ^2_{hit}	$\chi^2_{\alpha,df}$	p_value
I	6	5	128,78	11,070	<0,0001
	12	11	156,48	19,675	<0,0001
	24	23	180,71	35,172	<0,0001
II	6	2	106,49	5,991	<0,0001
	12	8	125,09	15,507	<0,0001
	24	20	173,08	31,41	<0,0001
III	12	6	37,16	12,592	<0,0001
	24	18	65,23	28,869	<0,0001
	36	30	83,81	43,773	<0,0001

Uji normalitas residual dilakukan untuk melihat kenormalan dari residual. Model dikatakan baik jika residualnya berdistribusi normal terjadi jika histogram residual mempunyai kecenderungan membentuk pola lonceng (*bell shape*). Selain

itu, untuk menguji normalitas residual dapat digunakan uji hipotesis, diantaranya uji Jarque-Bera, uji Kolmogorov-smirnov ($n > 50$) dan uji Shapiro-Wilk ($n < 50$).

Pengujian normalitas terhadap *error* model dugaan dilakukan dengan hipotesis sebagai berikut ini:

H_0 : *Error* yang berdistribusi normal

H_1 : *Error* tidak berdistribusi normal

Dengan taraf signifikansi $\alpha = 0,05$ dan statistik uji yang digunakan adalah uji Kolmogorov-Smirnov. Pada pengujian ini dikatakan tolak H_0 jika $p_value < \alpha$ yang berarti *error* model dugaan tidak berdistribusi normal. Berdasarkan hasil perhitungan SAS dalam Tabel 4.5 menunjukkan bahwa ketiga model dugaan tidak berdistribusi normal karena p_value lebih kecil dari taraf signifikansi.

Tabel 4.5 Nilai statistik uji Kolmogorov-Smirnov

Model	Kolmogorov-Smirnov	p_value
I	0,057984	<0,0100
II	0,055761	<0,0100
III	0,058608	<0,0100

Dari pengecekan diagnosa, ketiga model *autoregressive* di atas tidak ada yang memenuhi asumsi *white noise* dan normalitas. Wong dan Li (2000) menjelaskan bahwa *mixture* dari komponen AR yang non-stasioner dan komponen AR yang stasioner menghasilkan sebuah proses yang stasioner menggunakan *Mixture Autoregressive*. Sehingga analisis akan dilanjutkan dengan menggunakan *Mixture Normal Autoregressive* (MNAR) yang diidentifikasi bahwa distribusinya adalah distribusi Normal. Analisis ini dilakukan dengan pendekatan *Bayesian*.

4.3. Model Bayesian Mixture Normal Autoregressive (MNAR)

Pembentukan model *Mixture Normal Autoregressive* (MNAR) bertujuan untuk menormalkan *error* dari model *autoregressive* yang telah diperoleh. Identifikasi adanya *mixture* secara visualisasi telah dijelaskan dalam Gambar 2.1 dan Gambar 2.2. Dari Gambar 2.2 terlihat bahwa adanya leptokurtik yaitu puncak yang cukup tinggi dan *fat-tails* yaitu ekor yang landai, sehingga mengindikasikan

data beban puncak ini berdistribusi lebih dari satu. Dengan pemodelan MNAR, pola data seperti itu bisa dipisah beberapa komponen dengan varians yang berbeda untuk mengakomodasi data *outlier*.


Dalam penelitian ini, model MNAR menggunakan banyaknya komponen *mixture* yaitu 2 (dua) dan 3 (tiga) komponen. MNAR dilakukan dengan pendekatan *Bayesian* yang diimplementasikan secara grafik dalam bentuk *doodle* WinBUGS. Secara matematis, model yang akan dicari adalah $MNAR(2; p_1, p_2)$ dan $MNAR(3; p_1, p_2, p_3)$ dengan model AR yang digunakan adalah model yang telah diperoleh dalam analisis sebelumnya. Data yang digunakan adalah data yang stasioner yaitu data yang telah di *differencing*.

4.3.1. Pemodelan MNAR ($2; p_1, p_2$)

Pemodelan MNAR dengan dua komponen *mixture* akan menghasilkan 3 model dari model AR yang telah diperoleh sebelumnya yaitu $MNAR(2; 1, [1, 2, 4, 6])$, $MNAR(2; 1, 6)$, dan $MNAR(2; [1, 2, 4, 6], 6)$. Berikut ini akan ditunjukkan hasil olahan WinBUGS untuk ketiga model MNAR tersebut dan juga interpretasinya.

i) $MNAR(2; 1, [1, 2, 4, 6])$

Model secara grafis digambarkan berupa *doodle* dari sekumpulan hubungan *node-node* dalam WinBUGS 1.4 seperti pada Lambar 4.10. *Listing program* atau *code* dari *doodle* ini dapat dilihat pada Lampiran 8.



Gambar 4.10 Struktur *doodle* WinBUGS dari $MNAR(2; 1, [1, 2, 4, 6])$

Node pada data *mixture* disimbolkan $Z[i]$ yang merupakan *node* yang stokastik berdistribusi Normal. *Node* yang stokastik tergantung pada *node logical* parameter $\mu[i]$ dan $\tau[i]$ yang masing-masing membutuhkan distribusi *prior node* stokastik yang berkaitan dengan parameter. *Prior* proporsi yang disimbolkan dalam *doodle* dengan P memiliki distribusi Dirichlet yang jumlahnya harus sama dengan 1. *Prior* parameter $b1[i]$, $b2[i]$, $b3[i]$, dan $b4[i]$ menggunakan distribusi Normal sedangkan *prior* parameter $\tau[i]$ menggunakan distribusi Gamma.

Proses kerja dilakukan secara hirarki, dimulai dengan pembangkitan data parameter dari semua *prior* yang independen. Setiap kali pembangkitan satu nilai *prior* parameter tertentu selalu memperhatikan sejumlah N data dalam struktur kotak sebagai bahan untuk menghitung *likelihood* dalam proses *full conditional*-nya. Demikian selanjutnya nilai bangkitan tersebut akan digunakan untuk mengestimasi *mean* model setiap komponen *mixture* dan akhirnya digunakan untuk menaksir *mean* model MNAR. Proses dilakukan secara iteratif sebanyak 10000 kali. Proses inilah yang dinamakan proses *Gibbs sampler*. Proses iterasi terjadi selama 39 detik untuk model MNAR (2; 1,[1,2,4,6]) dengan tidak melakukan *burn in* karena dari data awal sudah konvergen. Proses iterasi tersebut menghasilkan estimasi parameter yaitu ditunjukkan dalam Tabel 4.6.

Tabel 4.6 Estimasi Parameter 2 Komponen *Mixture* MNAR (2; 1,[1,2,4,6])

Parameter	Mean	2,5%	Median	97,5%
P[1]	0,5005	0,4839	0,5005	0,5171
P[2]	0,4905	0,4829	0,4905	0,5161
b1[1]	-0,3556	-0,3982	-0,3554	-0,3134
b1[2]	-0,4314	-0,4762	-0,4315	-0,3864
b2[2]	-0,2112	-0,2579	-0,211	-0,1661
b3[2]	-0,1003	-0,1425	-0,1003	-0,0579
b4[2]	-0,08115	-0,1235	-0,08132	-0,03916
Sigma[1]	2,434	2,355	2,433	2,513
Sigma[2]	2,367	2,291	2,367	2,448

Selanjutnya akan dilakukan pengujian hipotesis untuk setiap parameternya dengan hipotesis sebagai berikut:

$H_0 : \phi_{k,i} = 0$ yang berarti parameter tidak signifikan

$H_1 : \phi_{k,i} \neq 0$ yang berarti parameter signifikan

dengan k menyatakan banyaknya komponen *mixture* dan i menyatakan orde *autoregressive*. $b1[1]$ adalah $\phi_{1,1}$ dan $b1[2]$, $b2[2]$, $b3[2]$, dan $b4[2]$ adalah $\phi_{2,1}$, $\phi_{2,2}$, $\phi_{2,4}$, $\phi_{2,6}$. Tolak H_0 jika pada selang interval distribusi posterior tidak memuat nilai nol. Selang interval distribusi posterior dapat dilihat dari nilai *credible interval* 2.5% - 97.5%. Berdasarkan Tabel 4.6 terlihat bahwa *credible interval* tidak memuat nilai nol sehingga dapat disimpulkan tolak H_0 yang berarti bahwa parameter-parameter tersebut signifikan.

Model MNAR (2; 1,[1,2,4,6]) yang terbentuk untuk data beban puncak konsumsi listrik di Kupang direpresentasikan dalam persamaan berikut ini:

$$F(Z_t | F_{t-1}) = P_1 \Phi\left(\frac{e_t^1}{\sigma_1}\right) + P_2 \Phi\left(\frac{e_t^2}{\sigma_2}\right) \quad (4.1)$$

dengan

$$e_t^1 = Z_t^* + 0,3556Z_{t-1}^*$$

$$e_t^2 = Z_t^* + 0,4314Z_{t-1}^* + 0,2112Z_{t-2}^* + 0,1003Z_{t-4}^* + 0,08115Z_{t-6}^*$$


$$P_1 = 0,5005 \text{ dan } P_2 = 0,4995$$

$$\sigma_1 = 2,434 \text{ dan } \sigma_2 = 2,367$$

ii) MNAR (2; 1,6)

Secara grafis digambarkan ke dalam bentuk *doodle* dari sekumpulan hubungan *node-node* seperti pada Gambar 4.11. *Listing program* atau *code* dari *doodle* ini dapat dilihat pada Lampiran 11. *Node* pada data *mixture* disimbolkan $Z[i]$ yang merupakan *node* yang stokastik berdistribusi Normal dua parameter dengan indeks data subpopulasi. *Node* yang stokastik tergantung pada *node logical* parameter $\mu[i]$ dan $\tau[i]$ yang masing-masing membutuhkan distribusi *prior node* stokastik yang berkaitan dengan parameter. *Prior* parameter $b1[i]$, $b2[i]$, $b3[i]$, $b4[i]$, $b5[i]$, dan $b6[i]$ menggunakan distribusi Normal sedangkan

prior parameter $\tau_{ao}[i]$ menggunakan distribusi Gamma. *Prior* proporsi yang disimbolkan P dalam *doodle* memiliki distribusi Dirichlet yang jumlahnya harus sama dengan 1.



Gambar 4.11 Struktur *doodle* WinBUGS dari MNAR (2; 1,6)

Proses iterasi sama dengan model sebelumnya yang dilakukan sebanyak 10000 kali dengan waktu *running* selama 47 detik untuk model ini. Pada proses ini tidak dilakukan *burn in* karena sejak awal sudah konvergen. Hasil estimasi ditampilkan dalam Tabel 4.7.

Tabel 4.7 Estimasi Parameter 2 Komponen *Mixture* MNAR (2; 1,6)

Parameter	Mean	2,5%	Median	97,5%
P[1]	0,5007	0,4843	0,5008	0,5168
P[2]	0,4993	0,4832	0,4992	0,5157
b1[1]	-0,3556	-0,399	-0,3556	-0,3123
b1[2]	-0,5178	-0,5634	-0,5177	-0,4733
b2[2]	-0,3689	-0,4194	-0,3693	-0,3189
b3[2]	-0,2987	-0,3497	-0,2987	-0,2472
b4[2]	-0,2894	-0,3413	-0,2893	-0,2379
b5[2]	-0,192	-0,2425	-0,192	-0,1409
b6[2]	-0,1747	-0,2199	-0,1745	-0,1301

Sigma[1]	2,434	2,356	2,433	2,514
Sigma[2]	2,28	2,206	2,28	2,359

Akan dilakukan pengujian hipotesis untuk mengetahui parameter – parameter tersebut sudah signifikan atautkah belum dengan hipotesis sebagai berikut:

$H_0 : \phi_{k,i} = 0$ yang berarti parameter tidak signifikan

$H_1 : \phi_{k,i} \neq 0$ yang berarti parameter signifikan

dengan k menyatakan banyaknya komponen *mixture* dan i menyatakan orde *autoregressive*. b1[1] adalah $\phi_{1,1}$ dan b1[2], b2[2], b3[2], b4[2], b5[2], dan b6[2] adalah $\phi_{2,1}, \phi_{2,2}, \phi_{2,3}, \phi_{2,4}, \phi_{2,5}, \phi_{2,6}$. Tolak H_0 jika pada selang interval distribusi posterior tidak memuat nilai nol. Selang interval distribusi posterior dapat dilihat dari nilai *credible interval* 2,5% - 97,5%. Berdasarkan Tabel 4.7 terlihat bahwa *credible interval* tidak memuat nilai nol sehingga dapat disimpulkan parameter-parameter tersebut signifikan.

Model MNAR (2; 1,6) yang terbentuk untuk data beban puncak konsumsi listrik di Kupang direpresentasikan dalam Persamaan (4.1) dengan

$$e_t^1 = Z_t^* + 0,3556Z_{t-1}^*$$


$$e_t^2 = Z_t^* + 0,5178Z_{t-1}^* + 0,3689Z_{t-2}^* + 0,2987Z_{t-3}^* + 0,2894Z_{t-4}^* + 0,192Z_{t-5}^* + 0,1747Z_{t-6}^*$$

$$P_1 = 0,5007 \text{ dan } P_2 = 0,4993$$

$$\sigma_1 = 2,434 \text{ dan } \sigma_2 = 2,28$$

iii) MNAR (2; [1,2,4,6],6)

Model MNAR ini direpresentasikan ke dalam bentuk *doodle* yang digambarkan seperti pada Gambar 4.12 dan *code* dari *doodle* ini dapat dilihat pada Lampiran 14.



Gambar 4.12 Struktur *doodle* WinBUGS dari MNAR (2; [1,2,4,6],6)

Node yang stokastik tergantung pada *node logical* parameter $\mu[i]$ dan $\tau[i]$ yang masing-masing membutuhkan distribusi *prior node* stokastik yang berkaitan dengan parameter. *Prior* parameter $b1[i]$, $b2[i]$, $b3[i]$, $b4[i]$, $b5[i]$, dan $b6[i]$ menggunakan distribusi Normal sedangkan *prior* parameter $\tau[i]$ menggunakan distribusi Gamma. *Prior* proporsi P memiliki distribusi Dirichlet yang jumlahnya harus sama dengan 1. Proses iterasi dilakukan sebanyak 10000 kali tanpa *burn in*. Proses *running* untuk model ini terjadi selama 71 detik. Hasil estimasi parameter yang konvergen ditampilkan dalam Tabel 4.8.

Tabel 4.8 Estimasi Parameter MNAR (2; [1,2,4,6],6)

Parameter	Mean	2,5%	Median	97,5%
P[1]	0,5	0,4836	0,5001	0,5161
P[2]	0,5	0,4839	0,4999	0,5164
b1[1]	-0,4314	-0,4759	-0,4314	-0,3862
b1[2]	-0,5177	-0,5632	-0,5175	-0,4729
b2[1]	-0,2113	-0,2566	-0,2113	-0,1669
b2[2]	-0,3691	-0,4184	-0,3696	-0,3178
b3[2]	-0,299	-0,3508	-0,2994	-0,2478

b4[1]	-0,1001	-0,1424	-0,1	-0,05791
b4[2]	-0,2898	-0,3411	-0,2901	-0,238
b5[2]	-0,1924	-0,2426	-0,1924	-0,1419
b6[1]	-0,08087	-0,1231	-0,08088	-0,03822
b6[2]	-0,1751	-0,2202	-0,1753	-0,1285
Sigma[1]	2,367	2,292	2,367	2,445
Sigma[2]	2,28	2,206	2,28	2,358

Selanjutnya akan dilakukan pengujian hipotesis untuk mengetahui signifikansi parameter – parameter dengan hipotesis sebagai berikut:

$H_0 : \phi_{k,i} = 0$ yang berarti parameter tidak signifikan

$H_1 : \phi_{k,i} \neq 0$ yang berarti parameter signifikan

dengan k menyatakan banyaknya komponen *mixture* dan i menyatakan orde *autoregressive*. b1[1], b2[1], b4[1], dan b6[1] adalah $\phi_{1,1}, \phi_{1,2}, \phi_{1,4}, \phi_{1,6}$ dan b1[2], b2[2], b3[2], b4[2], b5[2], dan b6[2] adalah $\phi_{2,1}, \phi_{2,2}, \phi_{2,3}, \phi_{2,4}, \phi_{2,5}, \phi_{2,6}$. Tolak H_0 jika pada selang interval distribusi posterior tidak memuat nilai nol, Selang interval distribusi posterior dapat dilihat dari nilai *credible interval* 2,5% - 97,5%. Berdasarkan Tabel 4.8 terlihat bahwa *credible interval* tidak memuat nilai nol sehingga dapat disimpulkan parameter-parameter tersebut signifikan.

Model MNAR (2; [1,2,4,6],6) yang terbentuk untuk data beban puncak konsumsi listrik di Kupang direpresentasikan dalam Persamaan (4.1) dengan

$$e_t^1 = Z_t^* + 0,4314Z_{t-1}^* + 0,2113Z_{t-2}^* + 0,1001Z_{t-4}^* + 0,08087Z_{t-6}^*$$

$$e_t^2 = Z_t^* + 0,5177Z_{t-1}^* + 0,3691Z_{t-2}^* + 0,299Z_{t-3}^* + 0,2898Z_{t-4}^* + 0,1924Z_{t-5}^* + 0,1751Z_{t-6}^*$$

$$P_1 = 0,5 \text{ dan } P_2 = 0,5$$


$$\sigma_1 = 2,367 \text{ dan } \sigma_2 = 2,28$$

4.3.2. Pemodelan MNAR (3; p_1, p_2, p_3)

Setelah melakukan pemodelan untuk 2 komponen *mixture* selanjutnya akan dilakukan pemodelan dengan 3 komponen *mixture*, Dari pemodelan 3 komponen *mixture* ini diharapkan lebih baik dari ketiga model 2 komponen

mixture, Model ini secara grafis digambarkan dalam bentuk *doodle* yang ditunjukkan pada Gambar 4.13 dan *code* atau *listing program* dapat dilihat pada Lampiran 17.

Node pada data *mixture* disimbolkan $Z[i]$ yang merupakan *node* yang stokastik berdistribusi Normal. *Node* yang stokastik tergantung pada *node logical* parameter $\mu[i]$ dan $\tau[i]$ yang masing-masing membutuhkan distribusi *prior node* stokastik yang berkaitan dengan parameter. *Prior* proporsi yang disimbolkan dalam *doodle* dengan P memiliki distribusi Dirichlet yang jumlahnya harus sama dengan 1. *Prior* parameter $b1[i]$, $b2[i]$, $b3[i]$, $b4[i]$, $b5[i]$, dan $b6[i]$ menggunakan distribusi Normal sedangkan *prior* parameter $\tau[i]$ menggunakan distribusi Gamma.



Gambar 4.13 Struktur *doodle* WinBUGS 3 komponen *mixture* atau model MNAR (3; 1,[1,2,4,6],6).

Proses iterasi terjadi seperti pada model MNAR 2 komponen *mixture* yaitu menggunakan proses *Gibbs sampler* yang dilakukan perulangan sebanyak 10000 kali. Proses *running* data terjadi selama 91 detik tanpa *burn in*. Alasan tidak *burn in* karena sejak awal data sudah konvergen dan tidak bermasalah. Parameter yang telah diestimasi hasilnya dalam Tabel 4.9 berikut ini.

Tabel 4.9 Estimasi Parameter MNAR (3; 1,[1,2,4,6],6)

Parameter	Mean	2,5%	Median	97,5%
P[1]	0,3338	0,321	0,3339	0,3463
P[2]	0,333	0,3201	0,333	0,3458
P[3]	0,3331	0,3206	0,3331	0,3458
b1[1]	-0,3563	-0,3996	-0,3563	-0,3134
b1[2]	-0,4312	-0,4758	-0,4311	-0,3867
b1[3]	-0,5177	-0,5627	-0,5177	-0,4731
b2[2]	-0,2105	-0,256	-0,2104	-0,1659
b2[3]	-0,3693	-0,4201	-0,3694	-0,3192
b3[3]	-0,2991	-0,3496	-0,2993	-0,247
b4[2]	-0,1004	-0,1423	-0,1007	-0,05769
b4[3]	-0,2893	-0,3406	-0,2894	-0,2378
b5[3]	-0,1924	-0,2427	-0,1926	-0,1409
b6[2]	-0,08127	-0,1238	-0,08126	-0,03813
b6[3]	-0,1748	-0,22	-0,175	-0,1303
Sigma[1]	2,435	2,356	2,435	2,516
Sigma[2]	2,367	2,291	2,366	2,477
Sigma[3]	2,279	2,207	2,279	2,356

Selanjutnya akan dilakukan pengujian hipotesis untuk mengetahui signifikansi parameter-parameter dengan hipotesis sebagai berikut:

$H_0 : \phi_{k,i} = 0$ yang berarti parameter tidak signifikan

$H_1 : \phi_{k,i} \neq 0$ yang berarti parameter signifikan

dengan k menyatakan banyaknya komponen *mixture* dan i menyatakan orde *autoregressive*. b1[1] adalah $\phi_{1,1}$. b1[2], b2[2], b4[2], dan b6[2] masing - masing adalah $\phi_{2,1}$, $\phi_{2,2}$, $\phi_{2,4}$, $\phi_{2,6}$. b1[3], b2[3], b3[3], b4[3], b5[3], dan b6[3] masing - masing adalah $\phi_{3,1}$, $\phi_{3,2}$, $\phi_{3,3}$, $\phi_{3,4}$, $\phi_{3,5}$, $\phi_{3,6}$. Tolak H_0 jika pada selang interval distribusi posterior tidak memuat nilai nol. Selang interval distribusi posterior dapat dilihat dari nilai *credible interval* 2,5% - 97,5%. Berdasarkan Tabel 4.9

terlihat bahwa *credible interval* tidak memuat nilai nol sehingga dapat disimpulkan parameter - parameter tersebut signifikan.

Model MNAR (3; 1,[1,2,4,6],6) yang terbentuk untuk data beban puncak konsumsi listrik di Kupang direpresentasikan dalam persamaan berikut ini:

$$F(Z_t | F_{t-1}) = P_1 \Phi\left(\frac{e_t^1}{\sigma_1}\right) + P_2 \Phi\left(\frac{e_t^2}{\sigma_2}\right) + P_3 \Phi\left(\frac{e_t^3}{\sigma_3}\right) \quad (4.2)$$

$$e_t^1 = Z_t^* + 0,3563Z_{t-1}^*$$

$$e_t^2 = Z_t^* + 0,4312Z_{t-1}^* + 0,2105Z_{t-2}^* + 0,1004Z_{t-4}^* + 0,08127Z_{t-6}^*$$

$$e_t^3 = Z_t^* + 0,5177Z_{t-1}^* + 0,3693Z_{t-2}^* + 0,2991Z_{t-3}^* + 0,2893Z_{t-4}^* + 0,1924Z_{t-5}^* + 0,1748Z_{t-6}^*$$

$$P_1 = 0,3338, P_2 = 0,333, \text{ dan } P_3 = 0,3331$$

$$\sigma_1 = 2,435, \sigma_2 = 2,367, \text{ dan } \sigma_3 = 2,279$$

Pada pemodelan 3 komponen *mixture* ini ataupun pada 2 komponen *mixture* terlihat bahwa nilai variansi berbeda yang menjelaskan bahwa masing-masing komponen *mixture* dapat menangkap data *outlier*. Variansi tertinggi menangkap data yang bersifat *fat-tails* dan variansi terendah menangkap data yang bersifat *leptokurtic*. Inilah yang menyebabkan data tidak bisa dimodelkan dengan satu model saja karena tidak akan mengakomodir data *outlier*.

4.3.3. Seleksi Model Terbaik

Seleksi model terbaik antara 2 komponen dan 3 komponen *mixture* dapat dipilih berdasarkan nilai DIC. DIC (*Deviance Information Criterion*) merupakan suatu statistik yang digunakan untuk seleksi model yang terdapat dalam *tool* WinBUGS. DIC diperkenalkan oleh Spiegelhalter *et al.* pada tahun 2002 untuk penilaian model dan perbandingan model terinspirasi oleh model linear dan model linear umum. DIC menggunakan kriteria untuk membandingkan model berdasarkan *trade-off* antar model fit dan kompleksitas model. Pada tahun 2006. Celeux *et al.* mengkaji lagi eksistensi DIC untuk model data *missing* pada distribusi *mixture* dan model *random effect* (Celeux *et al.*, 2006).

Nilai DIC yang minimum menunjukkan model tersebut merupakan model terbaik yang selanjutnya akan digunakan untuk melakukan peramalan. Peramalan

yang dilakukan adalah peramalan jangka pendek. Nilai DIC yang diperoleh dari proses *running* data untuk model MNAR 2 dan 3 komponen *mixture* ditampilkan dalam Tabel 4.10.

Tabel 4.10 Nilai DIC Model MNAR

Model MNAR	Nilai DIC
(2; 1,[1,2,4,6])	16723,6
(2; 1,6)	16588,5
(2; [1,2,4,6],6)	16467,6
(3; 1,[1,2,4,6],6)	24889,8

Bedasarkan Tabel 4.10 terlihat bahwa model dengan 2 komponen *mixture* yaitu MNAR (2; [1,2,4,6], 6) memiliki nilai DIC yang minimum dibandingkan dengan yang lainnya. Sehingga, model ini bisa digunakan untuk peramalan jangka pendek.

Lampiran 1

Input Program SAS untuk AR(1)

```
data listrik;
input z ;
datalines;

27.17
30.48
.
49.88
48.58
;

/*input data outlier*/
data listrik;
set listrik;
run;

/*proses identifikasi*/
proc arima data=listrik out=result1;
identify var=z (1)
nlag=36;
run;

/*proses estimasi*/
estimasi
p=(1)
noconstant;
run;

/*uji asumsi normal*/
forecast lead=12 out=fits1;
run;

proc univariate data=fits1 normal;
var residual;
run;
```

Lampiran 2

Input Program SAS untuk AR ([1,2, 4, 6])

```
data listrik;  
input z ;  
datalines;  
  
27.17  
30.48  
.  
.  
49.88  
48.58  
;  
  
/*input data outlier*/  
data listrik;  
set listrik;  
run;  
  
/*proses identifikasi*/  
proc arima data=listrik out=result1;  
identify var=z (1)  
nlag=36;  
run;  
  
/*proses estimasi*/  
estimasi  
p=(1,2,4,6)  
noconstant;  
run;  
  
/*uji asumsi normal*/  
forecast lead=12 out=fits1;  
run;  
  
proc univariate data=fits1 normal;  
var residual;  
run;
```

Lampiran 3

Input Program SAS untuk Model AR(6)

```
data listrik;  
input z ;  
datalines;  
  
27.17  
30.48  
.  
.  
49.88  
48.58  
;  
  
/*input data outlier*/  
data listrik;  
set listrik;  
run;  
  
/*proses identifikasi*/  
proc arima data=listrik out=result1;  
identify var=z (1)  
nlag=36;  
run;  
  
/*proses estimasi*/  
estimasi  
p=(1,2,3,4,5,6,12,13,28)  
noconstant;  
run;  
  
/*uji asumsi normal*/  
forecast lead=12 out=fits1;  
run;  
  
proc univariate data=fits1 normal;  
var residual;  
run;
```

Lampiran 4

Output SAS untuk Model AR(1)

The ARIMA Procedure					
Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	-0.35564	0.02189	-16.25	<.0001	1
Variance Estimate			5.920241		
Std Error Estimate			2.433154		
AIC			8425.664		
SBC			8431.173		
Number of Residuals			1825		

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	126.78	5	<.0001	-0.070	-0.216	-0.084	-0.093	-0.015	-0.044
12	156.48	11	<.0001	0.090	0.018	-0.018	0.011	-0.072	-0.046
18	180.71	17	<.0001	-0.002	0.069	0.023	0.012	-0.007	-0.087
24	205.57	23	<.0001	-0.039	0.056	0.080	-0.009	-0.034	0.034
30	226.91	29	<.0001	-0.013	-0.021	0.005	0.070	-0.057	-0.052
36	238.10	35	<.0001	0.049	0.017	-0.030	0.002	0.046	-0.016
42	249.32	41	<.0001	-0.009	-0.035	-0.024	0.031	0.015	0.054
48	258.48	47	<.0001	-0.031	-0.030	-0.015	-0.031	0.004	0.043

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.969511	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.057984	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.147351	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	11.78295	Pr > A-Sq	<0.0050

Lampiran 5

Output SAS untuk Model AR([1,2,4,6])

The ARIMA Procedure					
Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	-0.43028	0.02278	-18.89	<.0001	1
AR1,2	-0.21042	0.02285	-9.21	<.0001	2
AR1,3	-0.10012	0.02134	-4.69	<.0001	4
AR1,4	-0.08104	0.02140	-3.79	0.0002	6

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	106.49	2	<.0001	-0.045	-0.083	-0.206	-0.033	-0.075	0.020
12	125.09	8	<.0001	0.042	0.007	-0.013	-0.009	-0.075	-0.050
18	149.54	14	<.0001	-0.008	0.071	0.026	0.017	-0.024	-0.081
24	173.08	20	<.0001	-0.037	0.059	0.075	0.011	-0.034	0.030
30	189.90	26	<.0001	-0.020	0.001	-0.002	0.062	-0.057	-0.039
36	196.37	32	<.0001	0.034	0.015	-0.020	0.001	0.039	-0.011
42	208.50	38	<.0001	-0.013	-0.035	-0.029	0.032	0.016	0.054
48	217.84	44	<.0001	-0.032	-0.025	-0.029	-0.023	0.004	0.044

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.970293	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.055761	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	1.764515	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	10.06279	Pr > A-Sq	<0.0050	

Lampiran 6

OUTPUT SAS UNTUK MODEL AR([1,2,3,4,5,6])

The ARIMA Procedure					
Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	-0.51572	0.02309	-22.33	<.0001	1
AR1,2	-0.36706	0.02568	-14.29	<.0001	2
AR1,3	-0.29688	0.02624	-11.31	<.0001	3
AR1,4	-0.28754	0.02625	-10.95	<.0001	4
AR1,5	-0.19073	0.02573	-7.41	<.0001	5
AR1,6	-0.17410	0.02314	-7.52	<.0001	6
Variance Estimate			5.190008		
Std Error Estimate			2.278159		
AIC			8190.407		
SBC			8223.463		
Number of Residuals			1825		

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.007	-0.010	-0.019	-0.017	-0.030	-0.043
12	37.16	6	<.0001	-0.077	-0.046	-0.047	-0.007	-0.064	-0.047
18	46.50	12	<.0001	-0.021	0.034	0.002	0.008	-0.011	-0.058
24	65.23	18	<.0001	-0.019	0.056	0.065	0.015	-0.013	0.045
30	77.75	24	<.0001	0.002	0.004	-0.006	0.052	-0.052	-0.037
36	83.81	30	<.0001	0.039	0.013	-0.028	-0.001	0.025	-0.013
42	90.59	36	<.0001	-0.001	-0.032	-0.025	0.025	-0.003	0.037
48	95.37	42	<.0001	-0.033	-0.019	-0.007	-0.014	0.005	0.029

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W 0.964822	Pr < W	<0.0001	
Kolmogorov-Smirnov	D 0.058608	Pr > D	<0.0100	
Cramer-von Mises	W-Sq 1.964623	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq 11.16809	Pr > A-Sq	<0.0050	

Lampiran 7

PERBANDINGAN MODEL AUTOREGRESSIVE YANG SIGNIFIKAN

MODEL	NILAI AIC
AR(1)	8425.664
AR(2)	8668.444
AR(4)	8662.076
AR(6)	8661.929
AR([1,2,4,6])	8324.116
AR([2,4,6])	8648.61
AR([1,2,3,4,5,6])	8190.407

Lampiran 8

INPUT WINBUGS UNTUK 2 KOMPONEN MIXTURE MODEL AR(1) & AR([1,2,4,6])

```
model;
{
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b4[2] ~ dnorm( 0.0,1.0E-6)
  b3[2] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * Z1[i] + b2[T[i]] * Z2[i] + b3[T[i]] * Z3[i] + b4[T[i]] * Z4[i]
  }
  for( i in 1 : N ) {
    Z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  P[1:2] ~ ddirch(alpha[])
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tao[1])
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tao[2])
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b3[1] ~ dnorm( 0.0,1.0E-6)
  b4[1] ~ dnorm( 0.0,1.0E-6)
}
```


Lampiran 9





OUTPUT WINBUGS UNTUK 2 KOMPONEN MIXTURE MODEL $AR(1)$ & $AR([1,2,4,6])$











node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5005	0.0083728	2.936E-50.4839	0.5005	0.5171	1	10000	
P[2]	0.4995	0.0083728	2.936E-50.4829	0.4995	0.5161	1	10000	
b1[1]	-0.3556	0.02158	2.292E-4-0.3982	-0.3554	-0.3134	1	10000	
b1[2]	-0.4314	0.02282	2.383E-4-0.4762	-0.4315	-0.3864	1	10000	
b2[2]	-0.2112	0.02329	2.302E-4-0.2579	-0.211	-0.1661	1	10000	
b3[2]	-0.1003	0.02156	1.934E-4-0.1425	-0.1003	-0.0579	1	10000	
b4[2]	-0.08115	0.02155	2.173E-4-0.1235	-0.08132	-0.03916	1	10000	
sigma[1]	2.434	0.04043	3.945E-42.355	2.433	2.513	1	10000	
sigma[2]	2.367	0.03958	3.702E-42.291	2.367	2.448	1	10000	


Lampiran 10

PLOT TIME SERIES, DENSITY, DAN AUTOCORELATION UNTUK 2 KOMPONEN MIXTURE MODEL AR(1) & AR([1,2,4,6])









Lampiran 11

INPUT WINBUGS UNTUK 2 KOMPONEN MIXTURE MODEL AR(1) & AR([1,2,3,4,5,6])

```
model;
{
  b4[2] ~ dnorm( 0.0,1.0E-6)
  b3[2] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  b6[2] ~ dnorm( 0.0,1.0E-6)
  b5[2] ~ dnorm( 0.0,1.0E-6)
  b1[1] ~ dnorm( 0.0,1.0E-6)
  for( i in 1 : N ) {
    Z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * Z1[i] + b2[T[i]] * Z2[i] + b3[T[i]] * Z3[i] + b4[T[i]] * Z4[i] +
    b5[T[i]] * Z5[i] + b6[T[i]] * Z6[i]
  }
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirch(alpha[])
  tao[1] ~ dgamma(0.001,0.001)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tao[2])
  sigma[1] <- 1 / sqrt(tao[1])
  b3[1] ~ dnorm( 0.0,1.0E-6)
  b5[1] ~ dnorm( 0.0,1.0E-6)
  b6[1] ~ dnorm( 0.0,1.0E-6)
  b4[1] ~ dnorm( 0.0,1.0E-6)
  b2[1] ~ dnorm( 0.0,1.0E-6)
}
```


Lampiran 12





OUTPUT WINBUGS UNTUK 2 KOMPONEN MIXTURE MODEL AR(1) & AR([1,2,3,4,5,6])








node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5007	0.0082999	4.18E-50.4843	0.5008	0.5168	1	10000	
P[2]	0.4993	0.0082999	4.18E-50.4832	0.4992	0.5157	1	10000	
b1[1]	-0.3556	0.02189	1.945E-4-0.399	-0.3556	-0.3123	1	10000	
b1[2]	-0.5178	0.02316	2.642E-4-0.5634	-0.5177	-0.4733	1	10000	
b2[2]	-0.3689	0.0258	2.776E-4-0.4194	-0.3693	-0.3189	1	10000	
b3[2]	-0.2987	0.02605	2.743E-4-0.3497	-0.2987	-0.2472	1	10000	
b4[2]	-0.2894	0.02626	2.704E-4-0.3413	-0.2893	-0.2379	1	10000	
b5[2]	-0.192	0.026	2.792E-4-0.2425	-0.192	-0.1409	1	10000	
b6[2]	-0.1747	0.02312	2.187E-4-0.2199	-0.1745	-0.1301	1	10000	
sigma[1]	2.434	0.04008	4.18E-4 2.356	2.433	2.514	1	10000	
sigma[2]	2.28	0.0384	3.345E-42.206	2.28	2.359	1	10000	


Lampiran 13









PLOT TIME SERIES, DENSITY, DAN AUTOCORELATION UNTUK 2 KOMPONEN MIXTURE MODEL AR(1) & AR([1,2,3,4,5,6])











Lampiran 14

INPUT WINBUGS UNTUK 2 KOMPONEN MIXTURE MODEL AR([1,2,4,6]) & AR([1,2,3,4,5,6])

```
model;
{
  b4[2] ~ dnorm( 0.0,1.0E-6)
  b3[2] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  b6[2] ~ dnorm( 0.0,1.0E-6)
  b5[2] ~ dnorm( 0.0,1.0E-6)
  b1[1] ~ dnorm( 0.0,1.0E-6)
  for( i in 1 : N ) {
    Z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * Z1[i] + b2[T[i]] * Z2[i] + b3[T[i]] * Z3[i] + b4[T[i]] * Z4[i] +
    b5[T[i]] * Z5[i] + b6[T[i]] * Z6[i]
  }
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirch(alpha[])
  tao[1] ~ dgamma(0.001,0.001)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / tao[2]
  sigma[1] <- 1 / tao[1]
  b3[1] ~ dnorm( 0.0,1.0E-6)
  b5[1] ~ dnorm( 0.0,1.0E-6)
  b6[1] ~ dnorm( 0.0,1.0E-6)
  b4[1] ~ dnorm( 0.0,1.0E-6)
  b2[1] ~ dnorm( 0.0,1.0E-6)
}
```





Lampiran 15





OUTPUT WINBUGS UNTUK 2 KOMPONEN MIXTURE MODEL AR([1,2,4,6]) & AR([1,2,3,4,5,6])





node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5	0.0083089	9.422E-50.4836	0.5001	0.5161	1	10000	
P[2]	0.5	0.0083089	9.422E-50.4839	0.4999	0.5164	1	10000	
b1[1]	-0.4314	0.02272	2.087E-4-0.4759	-0.4314	-0.3862	1	10000	
b1[2]	-0.5177	0.023	2.342E-4-0.5632	-0.5175	-0.4729	1	10000	
b2[1]	-0.2113	0.02294	2.61E-4 -0.2566	-0.2113	-0.1669	1	10000	
b2[2]	-0.3691	0.02592	2.917E-4-0.4184	-0.3696	-0.3178	1	10000	
b3[2]	-0.299	0.02625	2.654E-4-0.3508	-0.2994	-0.2478	1	10000	
b4[1]	-0.1001	0.02137	2.101E-4-0.1424	-0.1	-0.057911		10000	
b4[2]	-0.2898	0.02653	2.767E-4-0.3411	-0.2901	-0.238	1	10000	
b5[2]	-0.1924	0.0256	2.672E-4-0.2426	-0.1924	-0.1419	1	10000	
b6[1]	-0.08087	0.0213	2.163E-4-0.1231	-0.08088	-0.038221		10000	
b6[2]	-0.1751	0.02323	2.339E-4-0.2202	-0.1753	-0.1285	1	10000	
sigma[1]	2.367	0.03908	4.074E-42.292	2.367	2.445	1	10000	
sigma[2]	2.28	0.03837	3.348E-42.206	2.28	2.358	1	10000	









Lampiran 16


PLOT TIME SERIES, DENSITY, DAN AUTOCORELATION UNTUK 2 KOMPONEN MIXTURE MODEL $AR([1,2,4,6])$
& $AR([1,2,3,4,5,6])$














Lampiran 17

INPUT WINBUGS UNTUK 3 KOMPONEN MIXTURE MODEL AR(1), AR([1,2,4,6]) & AR([1,2,3,4,5,6])

```
model;
{
  b4[1] ~ dnorm( 0.0,1.0E-6)
  b5[3] ~ dnorm( 0.0,1.0E-6)
  b3[3] ~ dnorm( 0.0,1.0E-6)
  b1[3] ~ dnorm( 0.0,1.0E-6)
  b6[3] ~ dnorm( 0.0,1.0E-6)
  b4[3] ~ dnorm( 0.0,1.0E-6)
  b2[3] ~ dnorm( 0.0,1.0E-6)
  b3[2] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  b4[2] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
  P[1:3] ~ ddirch(alpha[])
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:3])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * Z1[i] + b2[T[i]] * Z2[i] + b3[T[i]] * Z3[i] + b4[T[i]] * Z4[i] +
    b5[T[i]] * Z5[i] + b6[T[i]] * Z6[i]
  }
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  for( i in 1 : N ) {
    Z[i] ~ dnorm(mu[i],tau[i])
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tao[1])
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tao[2])
  tao[3] ~ dgamma(0.001,0.001)
  sigma[3] <- 1 / sqrt(tao[3])
  b5[2] ~ dnorm( 0.0,1.0E-6)
  b6[2] ~ dnorm( 0.0,1.0E-6)
  b3[1] ~ dnorm( 0.0,1.0E-6)
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b5[1] ~ dnorm( 0.0,1.0E-6)
  b6[1] ~ dnorm( 0.0,1.0E-6)
}
```


Lampiran 18





OUTPUT WINBUGS UNTUK 3 KOMPONEN MIXTURE MODEL AR(1), AR([1,2,4,6]) & AR([1,2,3,4,5,6])





node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.3338	0.006413	6.286E-50.321	0.3339	0.3463	1	10000	
P[2]	0.333	0.006465	6.439E-50.3204	0.333	0.3458	1	10000	
P[3]	0.3331	0.006414	7.543E-50.3206	0.3331	0.3458	1	10000	
b1[1]	-0.3563	0.02182	2.26E-4 -0.3996	-0.3563	-0.3134	1	10000	
b1[2]	-0.4312	0.0229	2.082E-4 -0.4758	-0.4311	-0.3867	1	10000	
b1[3]	-0.5177	0.0231	2.126E-4 -0.5627	-0.5177	-0.4731	1	10000	
b2[2]	-0.2105	0.02284	2.414E-4 -0.256	-0.2104	-0.1659	1	10000	
b2[3]	-0.3693	0.02553	2.312E-4 -0.4201	-0.3694	-0.3192	1	10000	
b3[3]	-0.2991	0.02619	2.515E-4 -0.3496	-0.2993	-0.247	1	10000	
b4[2]	-0.1004	0.02125	2.276E-4 -0.1423	-0.1007	-0.05769	1	10000	
b4[3]	-0.2893	0.0262	2.451E-4 -0.3406	-0.2894	-0.2378	1	10000	
b5[3]	-0.1924	0.0258	2.232E-4 -0.2427	-0.1926	-0.1409	1	10000	
b6[2]	-0.08127	0.02174	2.203E-4 -0.1238	-0.08126	-0.03813	1	10000	
b6[3]	-0.1748	0.02292	2.205E-4 -0.22	-0.175	-0.1303	1	10000	
sigma[1]	2.435	0.04063	4.045E-42.356	2.435	2.516	1	10000	
sigma[2]	2.367	0.03984	3.494E-42.291	2.366	2.447	1	10000	
sigma[3]	2.279	0.03799	3.63E-4 2.207	2.279	2.356	1	10000	





Lampiran 19












PLOT TIME SERIES, DENSITY, DAN AUTOCORELATION UNTUK 3 KOMPONEN MIXTURE MODEL $AR(1)$, $AR([1,2,4,6])$ & $AR([1,2,3,4,5,6])$









































BAB V

KESIMPULAN DAN SARAN

Pada bab ini disimpulkan mengenai hasil dan pembahasan yang telah dijelaskan pada bab sebelumnya dan untuk menjawab rumusan masalah pada bab pertama. Pada bab ini juga akan diberikan saran yang membangun untuk manfaat penelitian serta dapat dijadikan acuan untuk penelitian selanjutnya.

5.1. Kesimpulan

Berdasarkan hasil penelitian ini, diperoleh kesimpulan pemodelan beban puncak konsumsi listrik di Kupang menggunakan Bayesian *Mixture Normal Autoregressive* sebagai berikut:

1. Karakteristik dari data malam hari beban puncak konsumsi listrik di Kupang menunjukkan bahwa sering terjadi pemadaman aliran listrik karena kekurangan daya pada mesin pembangkit terlihat dari plot *time series* data. Peningkatan beban puncak lebih sering terjadi pada hari rabu, Kamis, dan jumat disebabkan oleh hari-hari raya secara nasional umumnya terjadi pada hari-hari tersebut yang menyebabkan naiknya pemakaian listrik di Kota Kupang. Pada hari raya keagamaan khususnya Kristen dan Katolik karena daerah ini merupakan daerah mayoritas, peningkatan beban puncak terjadi 3 hari sebelum hari raya. Secara bulanan, peningkatan beban puncak terjadi pada bulan Oktober dan November selama 5 tahun terakhir ini. Ini menunjukkan bulan-bulan tersebut merupakan bulan menjelang hari raya Natal yang menyebabkan pemakaian lampu hias dan yang lainnya meningkat. Ini merupakan kebiasaan masyarakat di Kupang. Secara tahunan, terjadi peningkatan dari tahun ke tahun untuk pemakaian listrik. Ini berarti dari tahun ke tahun terjadi pembangunan yang cukup signifikan dan menyebabkan naiknya rasio elektrifikasi.
2. Model *Autoregressive* yang teridentifikasi berdasarkan plot *PACF* adalah AR(1) disebut sebagai model I, AR([1,2,4,6]) sebagai model II, dan AR(6) sebagai model III. Model-model tersebut merupakan ketiga model yang dipilih dengan nilai AIC terendah dari beberapa model yang signifikan.

3. Model MNAR yang diperoleh untuk 2 dan 3 komponen *mixture* untuk data beban puncak konsumsi listrik di wilayah Kupang yang diimplementasikan pada WinBUGS yaitu sebagai berikut ini:

a. Model MNAR (2; 1,[1,2,4,6]) direpresentasikan dalam persamaan berikut ini:

$$F(Z_t | F_{t-1}) = P_1 \Phi\left(\frac{\hat{Z}_t^1}{\sigma_1}\right) + P_2 \Phi\left(\frac{\hat{Z}_t^2}{\sigma_2}\right)$$

dengan

$$\hat{Z}_t^1 = Z_t^* + 0.3556Z_{t-1}^*$$

$$\hat{Z}_t^2 = Z_t^* + 0.4314Z_{t-1}^* + 0.2112Z_{t-2}^* + 0.1003Z_{t-4}^* + 0.08115Z_{t-6}^*$$

$$P_1 = 0.5005 \text{ dan } P_2 = 0.4995$$

$$\sigma_1 = 2.434 \text{ dan } \sigma_2 = 2.367$$

b. Model MNAR (2; 1,6) direpresentasikan dalam persamaan berikut ini:

$$F(Z_t | F_{t-1}) = P_1 \Phi\left(\frac{\hat{Z}_t^1}{\sigma_1}\right) + P_2 \Phi\left(\frac{\hat{Z}_t^2}{\sigma_2}\right)$$

$$\hat{Z}_t^1 = Z_t^* + 0.3556Z_{t-1}^*$$

$$\hat{Z}_t^2 = Z_t^* + 0.5178Z_{t-1}^* + 0.3689Z_{t-2}^* + 0.2987Z_{t-3}^* + 0.2894Z_{t-4}^* + 0.192Z_{t-5}^* + 0.1747Z_{t-6}^*$$

$$P_1 = 0.5007 \text{ dan } P_2 = 0.4993$$

$$\sigma_1 = 2.434 \text{ dan } \sigma_2 = 2.28$$

c. Model MNAR (2; [1,2,4,6],6) direpresentasikan dalam persamaan berikut ini:

$$F(Z_t | F_{t-1}) = P_1 \Phi\left(\frac{\hat{Z}_t^1}{\sigma_1}\right) + P_2 \Phi\left(\frac{\hat{Z}_t^2}{\sigma_2}\right)$$

dengan

$$\hat{Z}_t^1 = Z_t^* + 0.4314Z_{t-1}^* + 0.2113Z_{t-2}^* + 0.1001Z_{t-4}^* + 0.08087Z_{t-6}^*$$

$$\hat{Z}_t^2 = Z_t^* + 0.5177Z_{t-1}^* + 0.3691Z_{t-2}^* + 0.299Z_{t-3}^* + 0.2898Z_{t-4}^* + 0.1924Z_{t-5}^* + 0.1751Z_{t-6}^*$$

$$P_1 = 0.5 \text{ dan } P_2 = 0.5$$

$$\sigma_1 = 2.367 \text{ dan } \sigma_2 = 2.28$$

- d. Model MNAR (3;1,[1,2,4,6],6) direpresentasikan dalam persamaan berikut ini:

$$F(Z_t | F_{t-1}) = P_1 \Phi\left(\frac{\hat{Z}_t^1}{\sigma_1}\right) + P_2 \Phi\left(\frac{\hat{Z}_t^2}{\sigma_2}\right) + P_3 \Phi\left(\frac{\hat{Z}_t^3}{\sigma_3}\right)$$

$$\hat{Z}_t^1 = Z_t^* + 0.3563Z_{t-1}^*$$

$$\hat{Z}_t^2 = Z_t^* + 0.4312Z_{t-1}^* + 0.2105Z_{t-2}^* + 0.1004Z_{t-4}^* + 0.08127Z_{t-6}^*$$

$$\hat{Z}_t^3 = Z_t^* + 0.5177Z_{t-1}^* + 0.3693Z_{t-2}^* + 0.2991Z_{t-3}^* + 0.2893Z_{t-4}^* + 0.1924Z_{t-5}^* + 0.1748Z_{t-6}^*$$

$$P_1 = 0.3338, P_2 = 0.333, \text{ dan } P_3 = 0.3331$$

$$\sigma_1 = 2.435, \sigma_2 = 2.367, \text{ dan } \sigma_3 = 2.279$$

5.2. Saran

Saran yang dapat diberikan berdasarkan penelitian ini antara lain sebagai berikut:

1. Pada penelitian selanjutnya, dapat dibuat syntax dalam program *Reversible Jump Markov Chain Monte Carlo* (RJMCMC) dalam mmenentukan banyaknya komponen *mixture* dari data tersebut sehingga dapat diketahui secara pasti banyaknya komponen *mixture*.
2. Pada penelitian selanjutnya, perlu dilakukan pengembangan untuk distribusi yang lainnya selain distribusi Normal.
3. Pada penelitian selanjutnya, dapat menggunakan data siang hari untuk beban puncak di Kupang kemudian dibandingkan hasilnya.

...halaman ini sengaja dikosongkan...

DAFTAR PUSTAKA

- Bernado, J. M. dan Giron, F. J., (1988). *A Bayesian Analysis of Simple Mixture Problem. Bayesian Statistic*, Volume 3, pp. 67-68.
- Box, G.E.P dan Tiao, G.C. (1973). *Bayesian Inference in Statistical Analysis*, Reading, MA: Addison-Wesley.
- Böhning, D., Seidel, W. (2003). Recent developments in mixture models. *Computational Statistics Data Analysis*, 41, 349–357.
- Carvalho, A. dan Tanner, M., (2005). Modelling Nonlinear Time Series with Local Mixtures of Generalized Linear Models. *The Canadian Journal of Statistics*, 33, 1-17.
- Carvalho, A. dan Tanner, M., (2005). Modelling Nonlinear Count Time Series with Local Mixtures of Poisson Autoregressive. *Computational Statistics and Data Analysis*, 51, 5266-5294.
- Carvalho, A. dan Tanner, M., (2006). Modelling Nonlinearities with Mixtures-of-Experts of Time Series Models. *International Journal of Mathematics and Mathematical Sciences*, 2006, 1-22.
- Casella, G. dan George, E. I., (1992). Explaining Gibbs Sampler. *The America Statistical Association*, 46(3), pp. 167-174.
- Celeux, G., Forbes, F., Robert, C. P., dan Titterington, D. M. (2006). Deviance Information Criteria For Missing data Models. *Bayesian Analysis*, 1, Number 4, pp. 651-674.
- Gamerman, D., (1997). *Markov Chain Monte Carlo*. London: Chapman dan Hall.
- Gelman, A., Carlin, J. B., Stern, H. S., dan Rubin, D. B., (2004). *Bayesian Data Analysis, 2nd edition*, Chapman dan Hall, Florida, hal 463-464.
- Geman, S. dan Geman, D., (1984). Stochastic Relaxation, Gibbs Sampler, and The Bayesian Restoration of Images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(6), pp. 721-741.
- Harsono, A. S., (2005). *Usulan Penggunaan Metode Fuzzy Artificial Neural Network untuk Peramalan Kebutuhan Listrik (Studi Kasus : PLN Area Pelayanan Malang*. Surabaya: Institut Teknologi Sepuluh Nopember.
- <http://www.esdm.go.id/berita/listrik/39-listrik/6373-pemakaian-listrik%09semester-12013-tumbuh-tinggi-di-sektor-produktif-dan-rendah-di%09kelompok-konsumtif.html>
- Iriawan, N., (2000). *Computationally Intensive Approaches to Inference in Neo-Normal Linear Models*, Australia : CUT.
- Iriawan, N., (2001). *Studi Tentang Bayesian Mixture Normal dengan Menggunakan Metode MCMC*, Surabaya : Lemlit ITS.
- Iriawan, N., (2003). *Teknik Simulasi*. Surabaya: s.n.

- Iriawan, N., (2012). *Pemodelan dan Analisis Data Driven Volume I*, Surabaya: ITS Press.
- Kartika, F. dan Iriawan, N., (2014). *Pengembangan Disagregasi Data Curah Hujan dengan Pendekatan Bayesian Mixture Neural Network Multioutput*. Surabaya : Institut Teknologi Sepuluh Nopember.
- King, R., Morgan, B., Giemenez, O., dan Brooks, S., (2010). *Bayesian Analysis for Population Ecology*. USA: Chapman and Hall.
- Koop, G., (2003). *Bayesian Econometrics*. England: Jhon Wiley and Sons, Inc.
- Lau, J. dan So, M., (2008). *Bayesian Mixture of Autoregressive Models. Computational Statistics and Data Analysis*, 53, 38-60.
- Marin, J. M., Mengersen, K. dan Robert, C. P., (2001). *Bayesian Modelling and Inference on Mixture of Distribution. Handbook of Statistics*, 25(50).
- Marsudi, D. (2006). *Operasi Sistem Tenaga Listrik*. Yogyakarta : Graha Ilmu.
- McLachlan, G., dan Basford, K. E., (1988). *Mixture Models : Inference and Application to Clustering*. New York : Marcel Dekker.
- McLachlan, G., dan Peel, D. A. (2000). *Finite Mixtture Models*. New York: Jhon Wiley
- Ntzoufras, I., (2009). *Bayesian Modelling using WinBUGS*. New York: Jhon Willey and Sons, Inc
- Rejki, N., (2015). *Bayesian Reversible Markov Chain Monte Carlo (RJMCMC) untuk Pemodelan Mixture Survival (Studi Kasus : Lama Pernikahan Para Pihak Mendaftarkan Gugatan Perceraian di Pengadilan Agama Kabupaten Malang Tahun 2014*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Silverman, B., (1986). *Density Estimation for Statistics and Data Analysis*. London: Chapman and Hall
- Prado, R., Molina, F. dan Huerta, G., (2006). Multivariate Time Series Modelling and Classification via Hierarchical VAR Mixtures. *Computational Statistics and Data Analysis*, 51, 1445-1462.
- Wei, W. W. S., (2006). *Time Series Analysis, Univariate and Multivariate Methods*. Addison-Wesley Publishing Co. Inc.
- Wong, C. S., dan Li, W. K., (2000). On a *Mixture Autoregressive Model*. *Journal of The Royal Statistical Society, Ser. B, Stat. Methodology*. 62(1), 95-115.
- Wong, C. S., dan Li, W. K., (2001). On Logistic *Mixture Autoregressive Model*. *Biometrika*. 88, 833-846.

BIOGRAFI PENULIS



Penulis dilahirkan Kota Kupang, Provinsi Nusa Tenggara Timur pada tanggal 6 Maret 1991, sebagai anak kedua dari pasangan Jarid Pallo dan Martha Ludji. Pendidikan formal yang telah ditempuh oleh penulis hingga saat ini adalah TK Anugerah Kupang (1995-1996), SD GMT Airnona 2 Kota Kupang (1996-2002), SMP Negeri 4 Kupang (2002-2005) dan SMA Negeri 1 Kupang (2005-2008).

Setelah tamat jenjang pendidikan SMA, Penulis melanjutkan studi di Universitas Negeri Nusa Cendana Kupang, jurusan Matematika Fakultas Sains dan Teknik (2008-2012). Setelah memperoleh gelar sarjana Sains, penulis bekerja sebagai pengajar tidak tetap di Universitas Swasta San Pedro Kupang. Sementara itu, Penulis juga melayani sebagai Bendaha Gereja di Gereja GMT Kemah Ibadat Airnona pada tahun 2013 sampai 2014. Pada tahun 2014, Penulis mendapatkan kesempatan untuk melanjutkan studi magister di Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember, Surabaya melalui program beasiswa Afirmasi dari Lembaga Pengelola Dana Pendidikan (LPDP).

Segala saran dan kritik yang membangun, sangat penulis harapkan untuk kebaikan tulisan dan karya kedepannya. Penulis dapat dihubungi di marchypallo@gmail.com.